

طراحی دو کلاسه ساز هوشمند MLP و RBF برای تخمین حالت سیستم توزیع و مقایسه خواص آنها

علیرضا فریدونیان

کارشناس ارشد، گروه مهندسی برق و کامپیوتر - دانشکده فنی - دانشگاه تهران

حمید لسانی

دانشیار، گروه مهندسی برق و کامپیوتر - دانشکده فنی - دانشگاه تهران

کارو لوکس

استاد، گروه مهندسی برق و کامپیوتر - دانشکده فنی - دانشگاه تهران

(تاریخ دریافت ۷۷/۴/۹، تاریخ تصویب ۷۸/۸/۲۲)

چکیده

برای تعیین استراتژی های کنترل در سیستم توزیع، و انجام تصمیم گیری های لازم توسط یک سیستم شناسنده الگو، لازم است حالت سیستم توزیع تخمین زده شود. در این سیستم، هر حالت، یک کلاس (دسته) از داده های اندازه گیری شده می باشد که بیانگر وضعیت سیستم در آن لحظه از زمان است.

در این مقاله پس از معرفی مسأله و بیان نیازهای موجود برای کار مورد نظر و بیان ضرورت تخمین گر حالت، دو تخمین گر با استفاده از شبکه عصبی با تقارن شعاعی^۱ و شبکه عصبی پرسپترون چند لایه^۲ طراحی و معرفی می شوند و نشان داده می شود که شبکه MLP در این کاربرد خاص کلاسه سازی^۳ از شبکه RBF بهتر عمل می نماید. همچنین اثر انواع توزیع داده ها در فضای کلاسه سازی، انجام عملیات مقیاس نمودن^۴، پیش-پردازش^۵، نرمالیزه نمودن و نگاشت همپیس^۶ روی فضای کلاسه سازی، اعمال نویز به ورودی سیستم، انتخاب بهینه^۷ درجه تابع خطا و کاهش بزرگترین خطای سیستم (نرم I-p) بر یادگیری، قدرت تعمیم^۸، درونیابی^۹ و برونیابی^۹ شبکه های عصبی مصنوعی بررسی شده است. در پایان، برای آزمون کارایی سیستم طرح شده در عمل، یک مثال عملی روی شبکه استاندارد به همراه نتایج شبیه سازی آن ارائه شده است.

واژه های کلیدی: سیستم های توزیع، تخمین گر حالت، کلاسه ساز، شبکه عصبی با تقارن شعاعی (RBF)، شبکه عصبی پرسپترون چند لایه (MLP)

مقدمه

دارد و عمل تخمین حالت سیستم بر اساس روشهای آماری کلاسیک مانند حداکثر شباهت، حداقل مربعات وزن دار، حداقل واریانس و یا روشهای هوشمند انجام میگیرد. مهمترین خواص یک سیستم هوشمند، توانایی یادگیری و قدرت تجرید و تعمیم می باشد. در سیستم های دینامیکی، یکی از اولین تخمین گرهای حالت، سیستم ریتگر منسوب به کالمن بنام فیلتر کالمن میباشد [۷].

کلاسه سازی مبنای شناخت است و هر زمینه از دانش با دسته بندی چیزهای مورد بحث خود در گروه هایی با مرزهای مشخص یا نامشخص آغاز میشود. یک سیستم کلاسه ساز سیستمی است که بر مبنای

حالت یک سیستم عبارتست از کوچکترین دسته از متغیرهای مستقل خطی، که میتوانند بیانگر وضعیت سیستم در هر لحظه از زمان باشند. حالت یک سیستم دینامیکی کوچکترین دسته از متغیرهای حالت است که با دانستن آنها در لحظه^۰ t_0 و ورودیها^۰ $t_0 \geq t$ ، بتوان رفتار سیستم را در هر لحظه $t_0 \geq t$ کاملاً تعیین نمود [۱۱]. در مطالعات استاتیکی، حالتهای استاتیکی در نظر گرفته میشود. تخمین حالت، عمل تخصیص مقدار به یک متغیر حالت نامعلوم سیستم برطبق معیاری بخصوص است که با استفاده از اندازه گیری در آن سیستم انجام میشود. معمولاً اندازه گیری حالات ناقص و اضافی

در کاربردهای تقریب تابع و شبکه های RBF در کاربردهای کلاسه سازی بهتر عمل می نمایند، اما در اینجا نشان داده میشود که این موضوع کلیت نداشته و در کاربرد مورد نظراین مقاله، شبکه MLP بهتر از شبکه RBF عمل مینماید. بموقع، علت و تفسیر فیزیکی این امر بیان خواهد شد.

سیستم قدرت الکتریکی بهم پیوسته - که بجرأت میتوان گفت بزرگترین و پیچیده ترین ساخته دست بشر از نظر گستردگی، قیمت و غیر خطی بودن میباشد - متشکل از زیرسیستم های تولید، انتقال و توزیع است. در این میان، زیرسیستم توزیع که وظیفه تحویل انرژی الکتریکی به مصرف کننده نهایی (پس از انتقال به محل مصرف) را بعهده دارد، بدلیل ارتباط بلافصل با مصرف کننده نهایی و سطح ولتاژ پایین تر نسبت به زیر سیستم های تولید و انتقال حائز اهمیت بسیاری است. از نظر قابلیت اعتماد و کاهش تلفات - میباشد. در سالهای اخیر، پروژه های متعددی در زمینه های سیستم های مدیریت توزیع^۲ و کنترل و اتوماسیون توزیع^۳ در کشورهای مختلف جهان پیاده شده است که شامل مؤلفه های مختلفی مانند: طراحی شبکه، تجدید آرایش فیدر، خازن گذاری بهینه و حفاظت بهینه می باشد و اهدافی از قبیل کاهش تلفات، ایجاد تعادل بار، افزایش قابلیت اعتماد شبکه، بازیابی سرویس شبکه، بهبود پروفیل ولتاژ و غیره را مد نظر داشته است. یک پروژه DMS یا DAC بدو زیرمسئله یا زیرسیستم تجزیه می شود:

• مسأله اصلی^۴: تعیین استراتژی های کنترلی یا مدیریتی برای نیل به اهداف مورد نظر و طراحی سیستم کنترل یا تصمیم گیرنده

• مسأله فرعی^۵: تهیه و تخمین اطلاعات مورد نیاز برای تصمیم گیری در زیرسیستم اصلی و طراحی تخمین گر حالت

سیستم قدرت دارای دو متغیر الکتریکی مختلط (فازوری) ولتاژ و توان (یا جریان) برای هر گره از شبکه است. در نظریه تحلیل سیستم های قدرت نشان داده میشود که متغیرهای سیستم قدرت با تقریب خوبی در دو کانال مجزای P و Q تغییر میکنند که در اینجا P ، Q ، θ و θ بترتیب توانهای حقیقی و موهومی و دامنه و فاز ولتاژ میباشد [۱۵]. از طرفی برای بررسی تابع تلفات خطوط، داشتن P و Q بتنهایی کفایت زیرا هدف نهایی

داده های گرفته شده از مجموعه تحت عمل کلاسه سازی، تعلق حالت مجموعه مذکور را به هر یک از کلاس ها مشخص می نماید. میتوان گفت که برای یک سیستم با حالات متناهی تخمین گر حالت سیستم یک کلاسه ساز است که نگاشتی از فضای داده های اندازه گیری شده از سیستم به فضای کلاس های متناهی سیستم انجام میدهد.

توسعه کاربردهای مختلف محاسباتی و کنترلی در سیستمها تحت شرایط متغیر، و نیاز به کار آنها بصورت دقیق و سریع و نیز پیچیدگی مدل ریاضی سیستمها در طبیعت، طراحی سیستمهای محاسب و کنترل کننده پیچیده و جدید که دارای ویژگیهای خاصی باشند را طلب می نماید. از جمله این ویژگیها، تطبیقی بودن، قدرت یادگیری، قدرت تعمیم، عدم نیازمندی به مدل دقیق ریاضی سیستم، مقاومت^۱ در مقابل اغتشاشات خارجی، خطای داخلی کم و قابل تحمل، عدم قطعیت و نیز غیر خطی بودن این سیستمها را می توان نام برد که منجر به بوجود آمدن سیستمهای هوشمندی مانند شبکه های عصبی مصنوعی، سیستمهای فازی، الگوریتم های ژنتیک و آبرکاری فولاد شده است [۱۶، ۹، ۲۶].

شبکه های عصبی مصنوعی سیستم های محاسباتی هستند که با تقلید از سیستم عصبی انسان ساخته شده اند و از پردازش موازی در تعداد زیادی واحد پردازنده ساده بهره می برند. اطلاعاتی که بصورت مثالهای متعدد از عملکرد سیستم به آنها داده می شود، بشکل انجمنی در وزنها بین واحدهای پردازنده، توزیع و ذخیره می شوند. شناسایی الگو کلاسه سازی جزء مهمترین زمینه های کاربرد شبکه های عصبی می باشد [۶].

کاربرد شناسایی الگوی شبکه های عصبی تحت دو زیرگروه کلاسه سازی و تقریب تابع بیان میشود ولی اگر از دیدگاه عمیق تری به این دو کاربرد نگریسته شود، بین آنها از نظر مفهومی و فلسفی تمایز خیلی مشخصی مشاهده نمی گردد، زیرا به تعبیری، از یکسو تقریب تابع یک نوع کلاسه سازی با تعداد کلاس های بسیار زیاد، و از دیگرسو، کلاسه سازی بمعنای تقریب زدن تابعی است که حاوی و متضمن ضوابط و اطلاعات لازم برای عمل کلاسه سازی میباشد. شبکه های RBF و MLP از معروفترین شبکه های عصبی با کاربرد در شناسایی الگو می باشند. در مرجع [۶] طی یک مثال گفته شده که شبکه های MLP

داشتن حالت سیستم می توان درک درستی از وضعیت بارگذاری شبکه بدست آورد.

مطالعات آنالیز حساسیت انجام شده نشان داده است که هر چه مقادیر توان حقیقی و مجازی تزریق شده بیشتر باشند و به مقادیر پیک (حداکثر) خود نزدیکتر شوند، حساسیت سطح بار افزایش می یابد، در نتیجه سطوح بار با مرتبه پایینتر باید دارای اندازه و گستردگی بیشتری باشند. بر این مبنا، چهار سطح بار با اندازه های ۴۰٪، ۲۵٪، ۲۰٪ و ۱۵٪ بترتیب به نامهای سطح بار ۱، سطح بار ۲، ... و سطح بار ۴ (ویا بطور متناظر حالت ۱، حالت ۲، ... و حالت ۴) در نظر گرفته می شوند.

پیش پردازش داده ها

توزیع داده ها

از مقایسه توابع انتقال نرون ها در شبکه های عصبی MLP و RBF مشاهده میگردد که نرون شبکه MLP در بیشتر فضا تحریک شده و فعال است (تابع انتقال سیگموئید)، اما نرون شبکه RBF در بیشتر فضا به آستانه تحریک نرسیده و غیر فعال می باشد (تابع انتقال گاوسی)، در نتیجه داده های با توزیع گاوسی برای شبکه عصبی با نرون های گاوسی (با تقارن شعاعی یا RBF) مناسب تر میباشند.

آموزش لایه میانی شبکه RBF (نرون های تابع انتقال گاوسی) با استفاده از یک الگوریتم بدون سرپرستی بنام K-Means Clustering انجام میپذیرد [۲، ۶]. این روش، همانگونه که از نامش پیداست، یک روش خوشه یابی میباشد، باین معنا که برای هر تمرکزی از داده ها بشکل یک خوشه، یک مرکز کلاس یا مرکز خوشه قائل میشود. این مرکز کلاس در حقیقت مقدار مرکزی (میانی) تابع انتقال گاوسی است که بشکل بدون سرپرستی فقط با تکیه بر مرکز ثقل داده های مجموعه آموزشی شبکه عصبی یافته میشود. بنابراین می توانیم بگوئیم شبکه عصبی RBF یک شبکه "حساس به مرکز" یا "مرکز گرا"^۳ میباشد. این امر در بخشهای بعد نشان داده خواهد شد.

از طرف دیگر، آموزش شبکه عصبی پرسپترون چند لایه MLP بصورت کاملاً باسرپرستی انجام می پذیرد و بنابراین میتوان بخوبی مرزهای کلاس ها را با آموزش مجموعه ای از داده ها با تمرکزی نسبی بر مرزهای کلاس

پروژه، تخمین سطح بار سیستم و در نتیجه بهینه سازی تلفات سیستم است. لذا بردار حالت سیستم، برداری در نظر گرفته میشود که مشتمل بر دو مقدار الکتریکی P و Q برای هر گره از شبکه (شینه) می باشد.

تخمین حالت در سیستم قدرت در اواخر ۱۹۶۰ مطرح شد و بتدریج در مراکز کنترل سیستم قدرت مورد استفاده قرار گرفت. مقالات بسیاری در این زمینه منتشر شده، از جمله Schwepe و همکاران [۱۳] روشهای مختلف تخمین حالت استاتیکی را مورد بررسی قرار دادند، Dopazo و همکاران [۵] روشهای ریاضی برای تخمین حالت سیستم قدرت ارائه نمودند، Simoes-Costa و همکاران [۱۴] یک روش عددی مقاوم (Robust) برای تخمین حالت سیستم قدرت عرضه نمودند، Allemong و همکاران [۱] یک تخمین گر حالت پیاده شده در مرکز کنترل سیستم قدرت را معرفی کردند. در زمینه تخمین گر های هوشمند سیستم قدرت نیز محققینی مانند Kim و همکاران [۸] و Santosو همکاران [۱۲] کارهای جالبی عرضه نمودند.

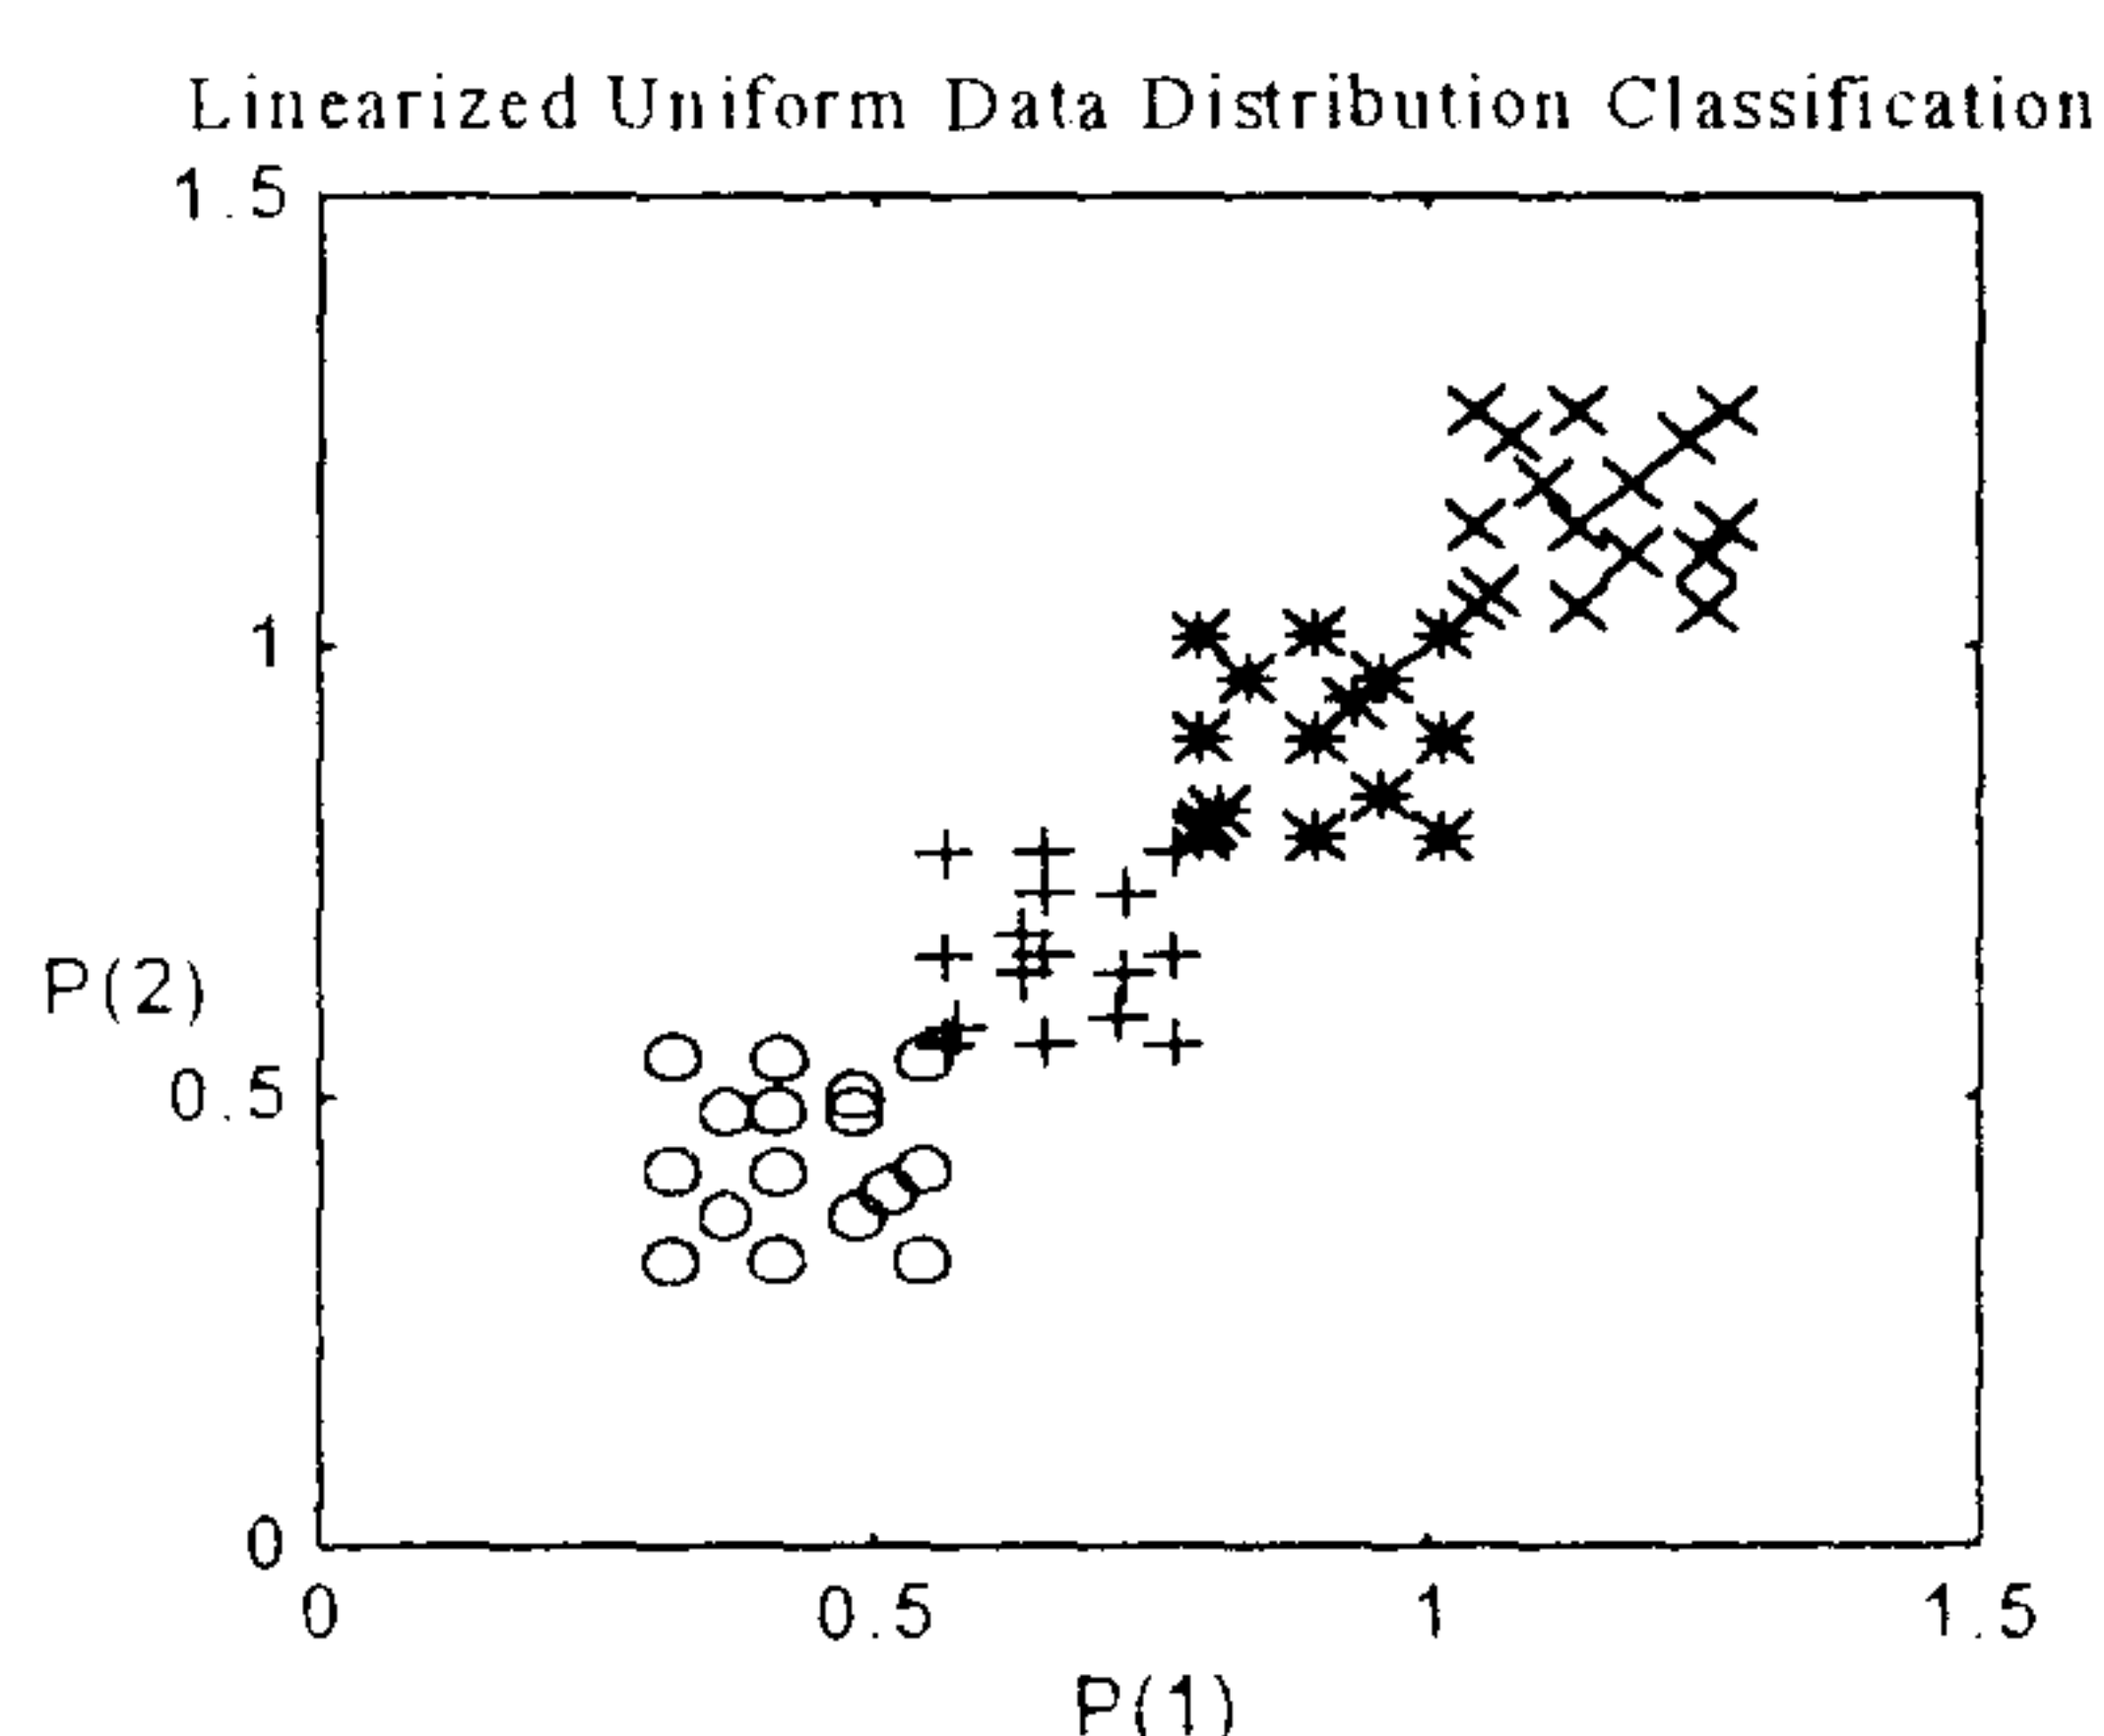
در این مقاله روشی نو و هوشمند برای تخمین حالت سیستم قدرت (مسأله فرعی ذکر شده در بالا) با استفاده از توانایی کلاسه سازی شبکه های عصبی مصنوعی ارائه شده و پس از طرح دو تخمین گر مبتنی بر شبکه های MLP و RBF، و مقایسه خواص آندو، شبکه MLP بدلیل ویژگیهای بهتر یادگیری، تعمیم، درونیایی و برونیایی نسبت به شبکه RBF برگزیده شده است. این تخمین گر در یک سیستم جامع بهینه ساز شبکه توزیع (مسأله اصلی ذکر شده در بالا) بکار گرفته شده که موضوع مقاله دیگری از همین مؤلفین بنام "بهینه سازی و اتوماسیون سیستم های توزیع بمنظور کاهش تلفات و ایجاد تعادل بار بکمک شبکه های عصبی" می باشد [۱۸].

بیان مسأله

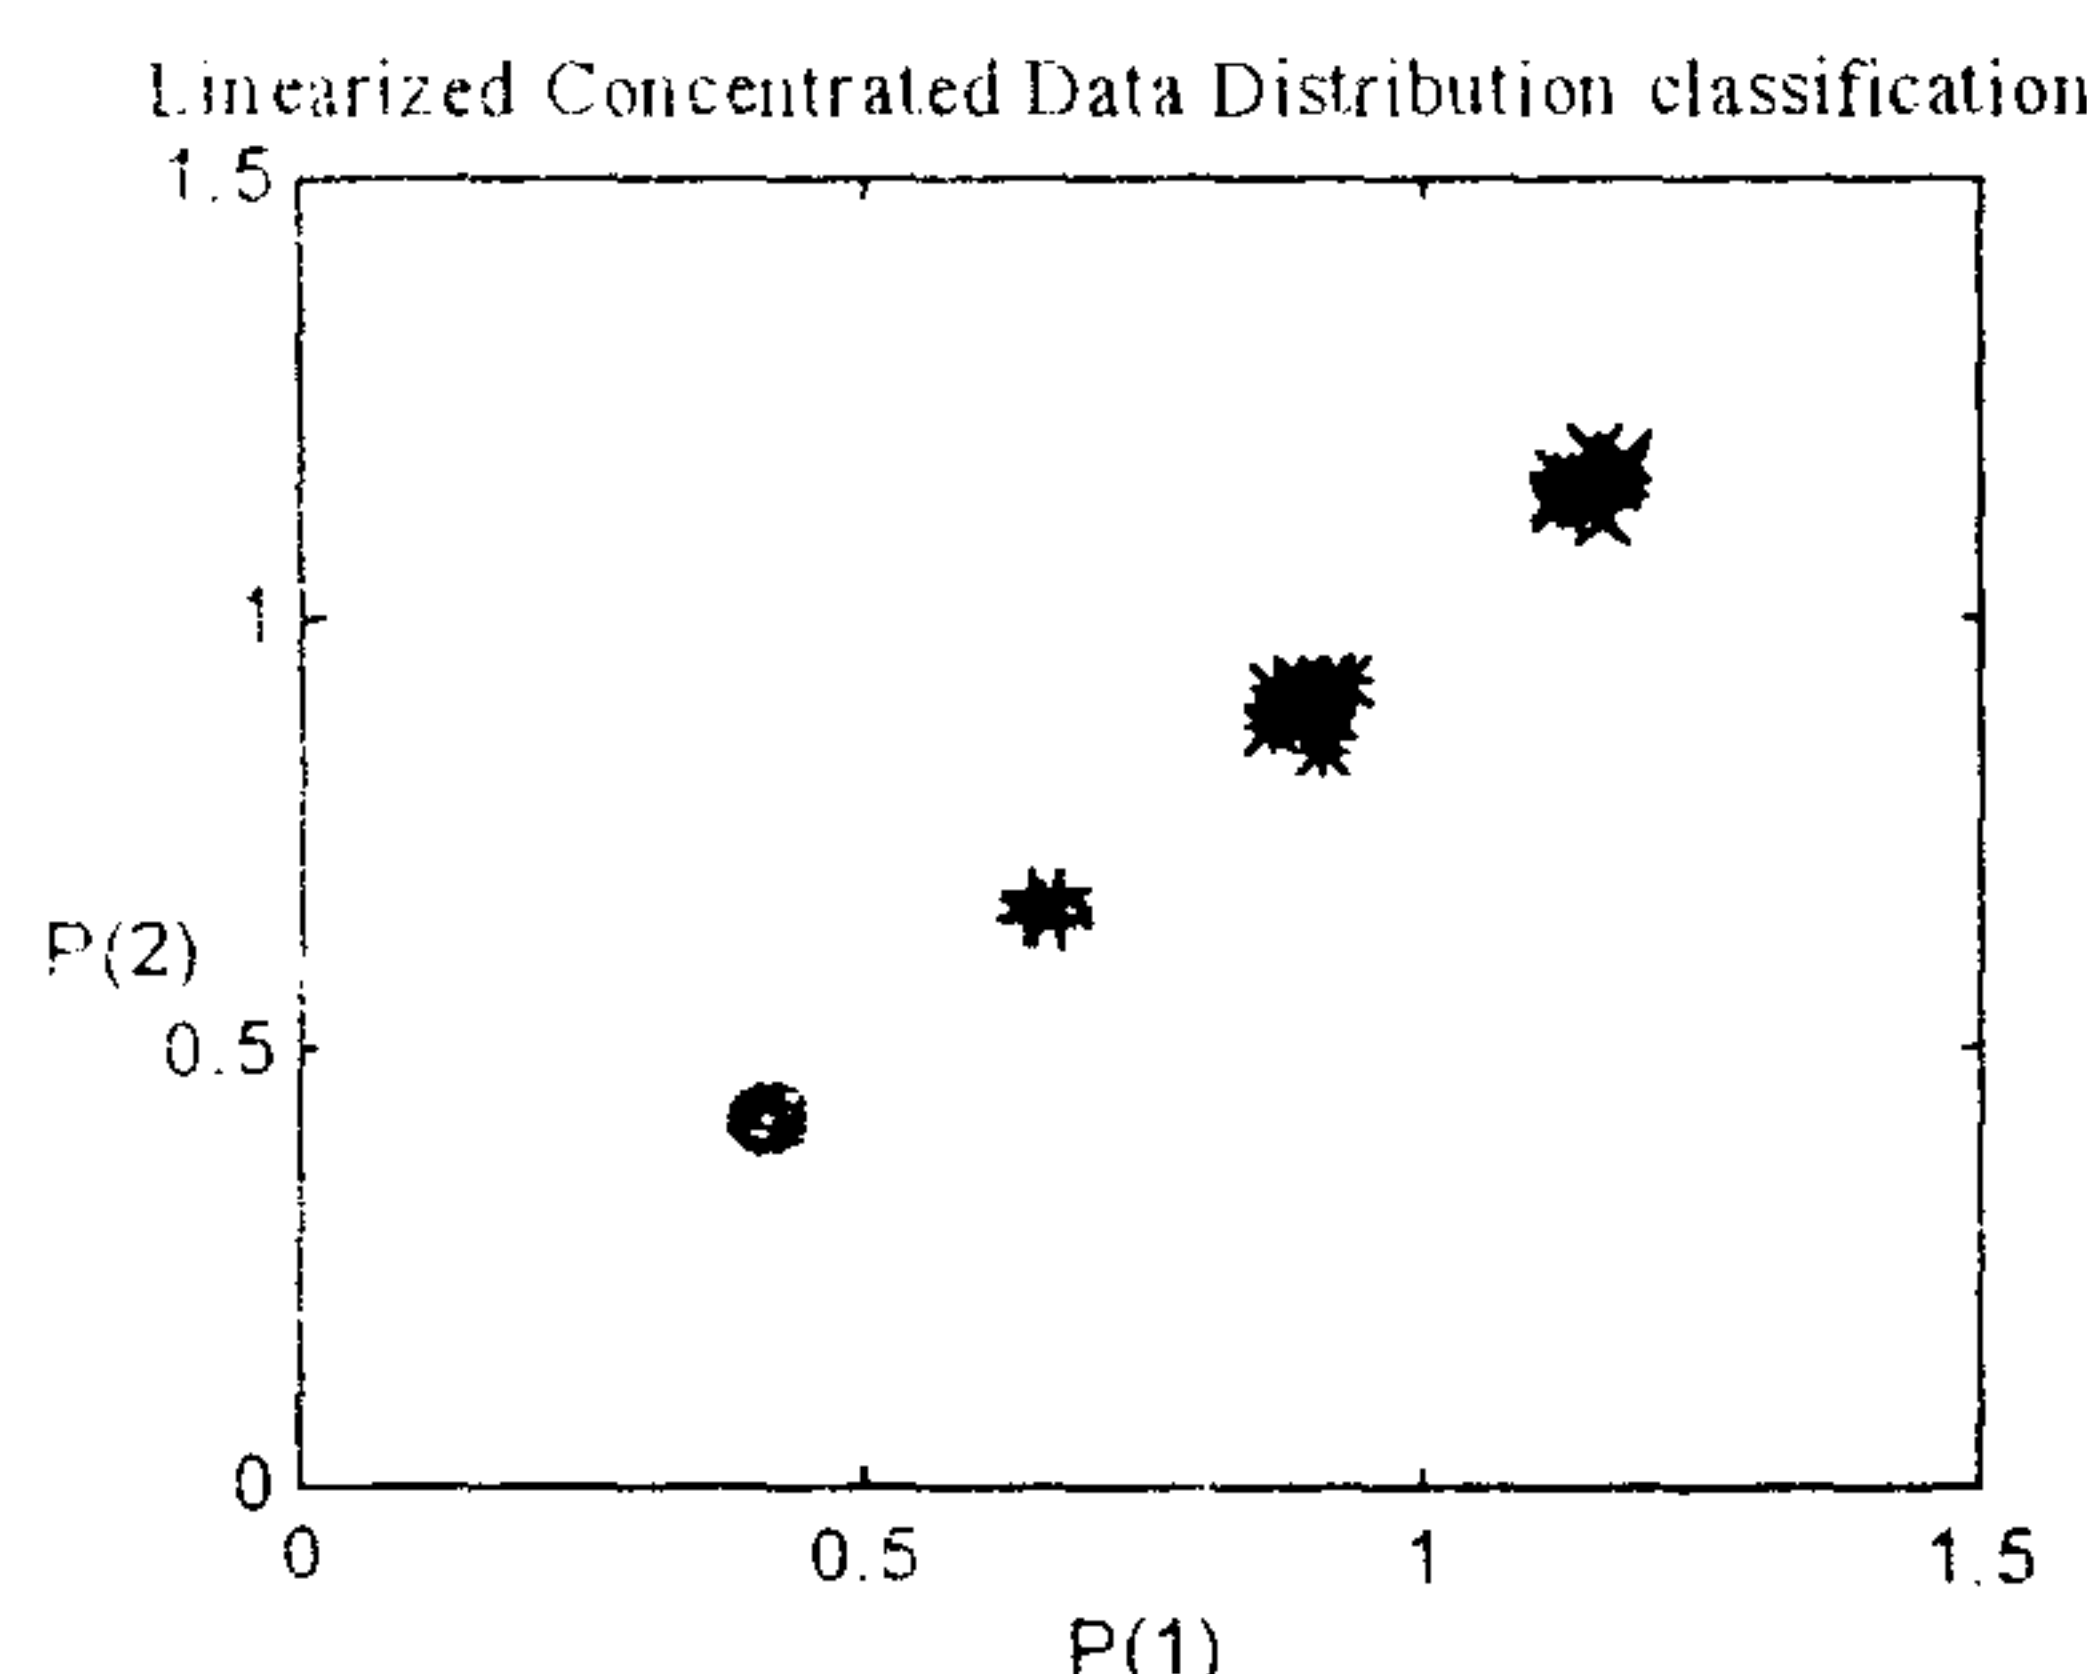
کلاسه ساز مورد نظر باید بتواند بر مبنای داده های ورودی که مقادیر توان حقیقی و مجازی تزریق شده در هر ناحیه بار (قطعه خط) می باشند، سطح بار^۱ آن ناحیه (ویا عبارت دیگر حالت آن ناحیه) را تخمین بزند. بدیهی است که این حالت ها کاملاً دینامیکی (پویا) بوده و با تغییر شرایط و مصارف شینه های^۲ سیستم توزیع، سطوح بار (حالت) آن نیز تغییر مینماید. در هر لحظه از زمان، با

خطی سازی فضا

از آنجا که شبکه های عصبی مصنوعی بر مبنای یک مدل ریاضی از نرون بیولوژیک استوار می باشند، قاعدتاً باید کلاس هایی که فاصله آنها از یکدیگر مضارب صحیحی از فاصله (اندازه) کلاس اول می باشد (یعنی فواصل خطی) آسانتر توسط شبکه آموخته شوند. بهمین دلیل توابع نمایی مختلف بررسی شده اند و درصد انحراف نسبی (انحراف در اندازه کلاس ها) بر حسب پایه های مختلف نگاشت در شکل (۳) رسم شده اند.



شکل ۴: فضای خطی شده مستطیلی با توزیع یکنواخت.



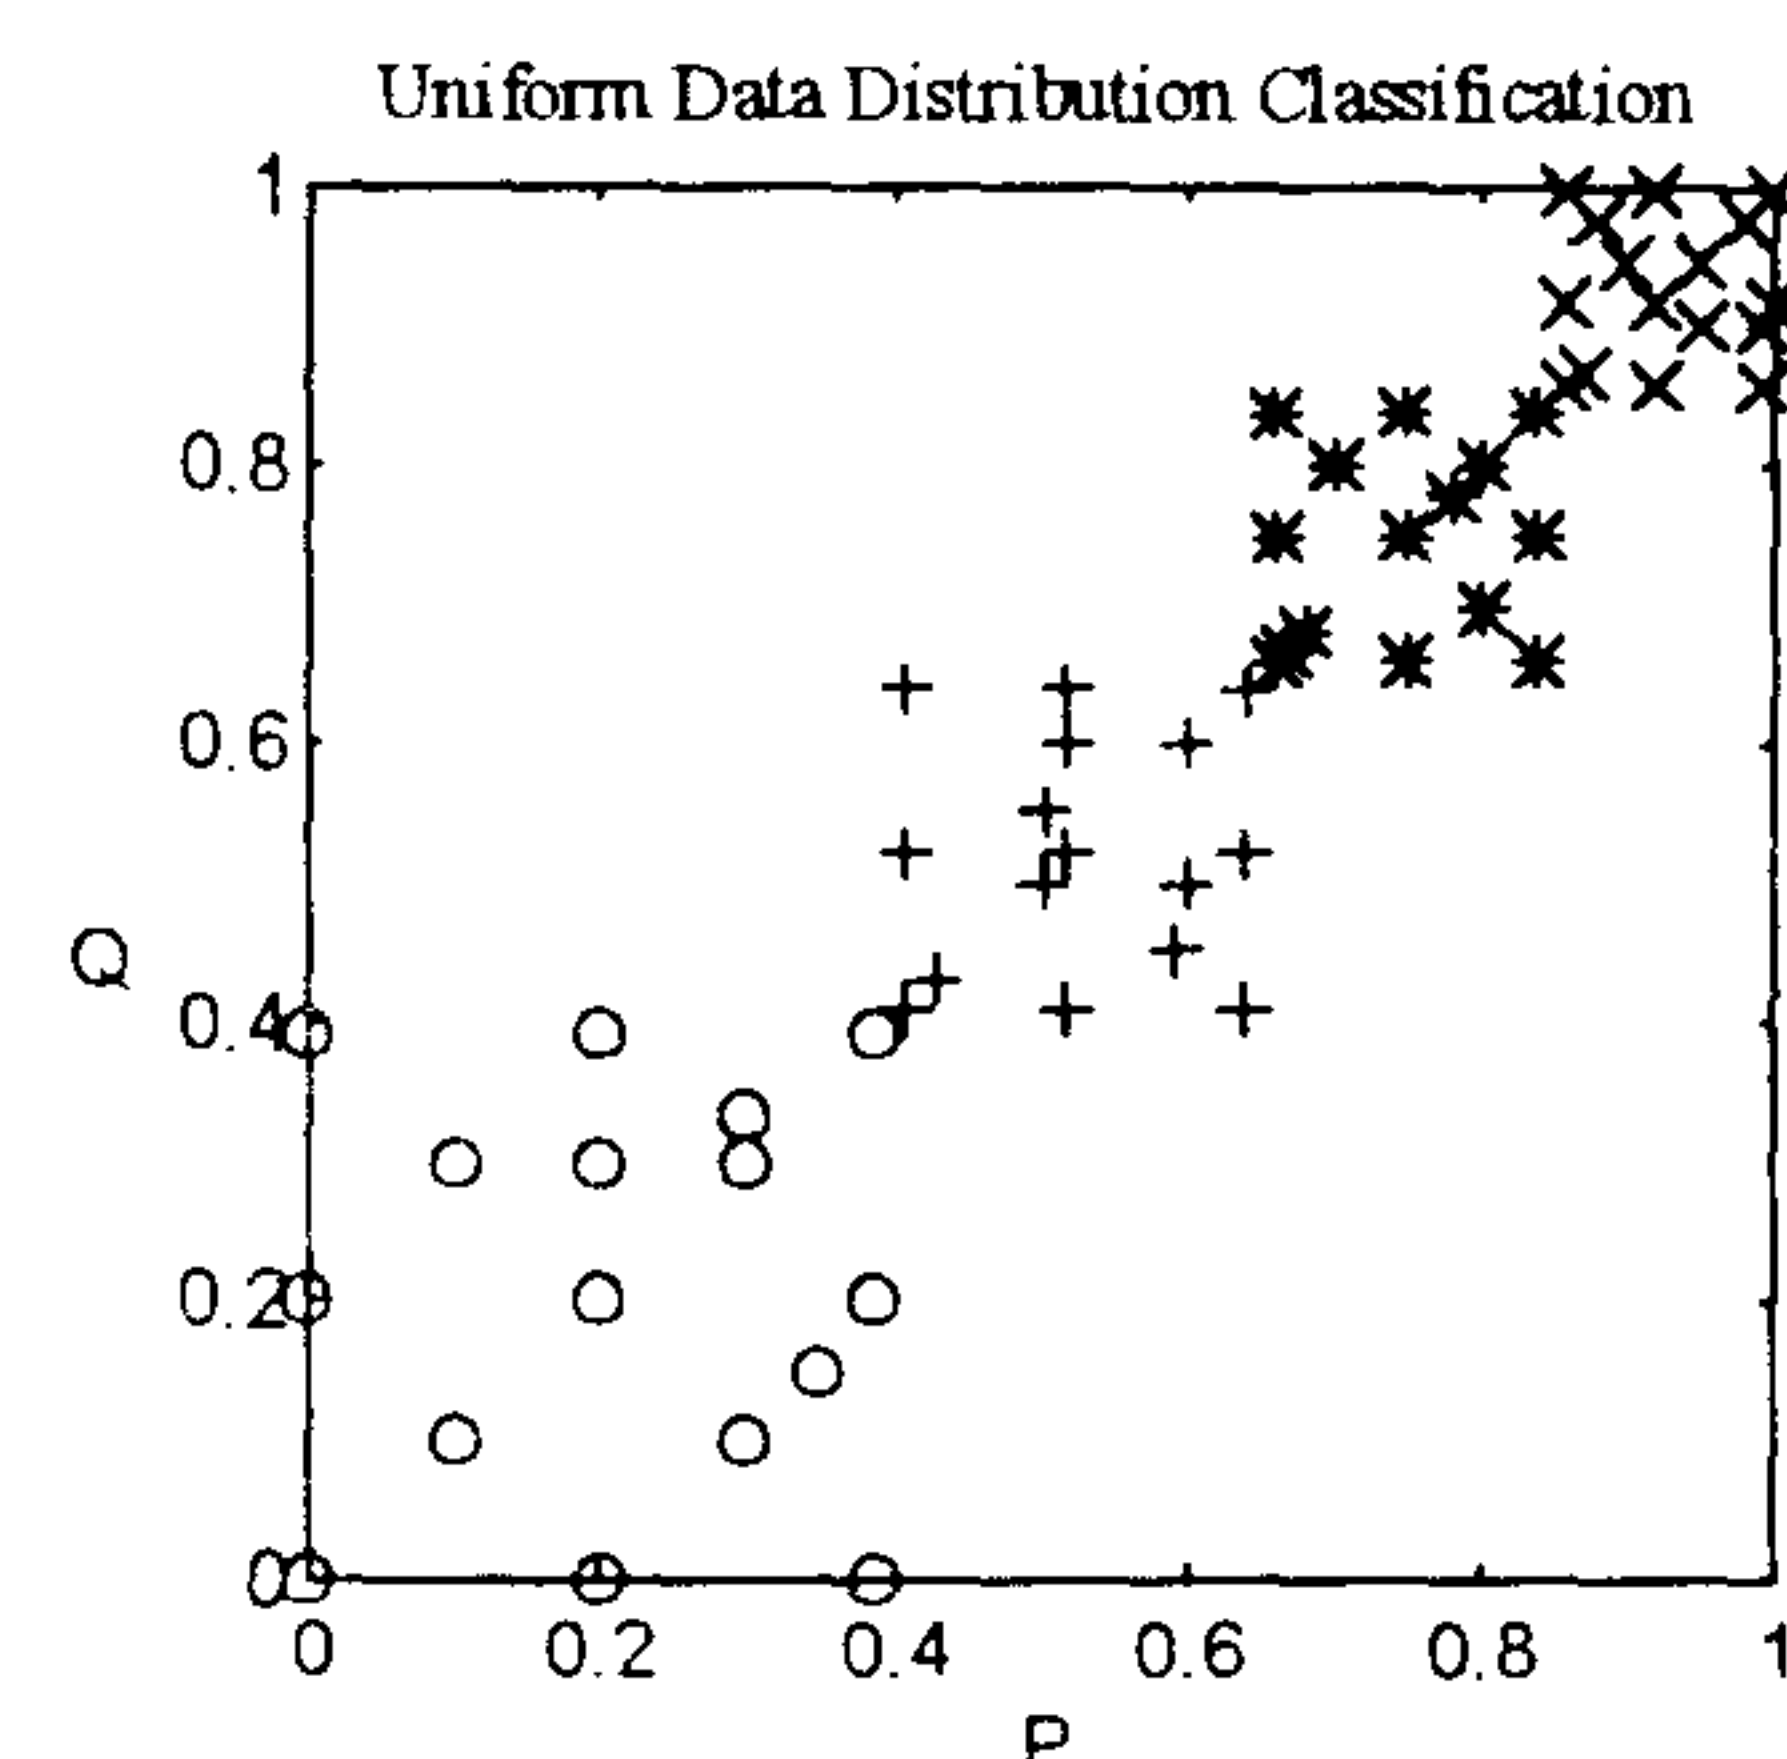
شکل ۵: فضای خطی شده مستطیلی با توزیع گاوسی.

همانگونه که ملاحظه می گردد، در صد انحراف بازی عدد صحیح چهار مینیمم می باشد، لذا تابع نمایی با پایه ۴ و نمای p انتخاب شده است. نتیجه انجام چنین نگاشتی به همراه ضرایب مقیاسی روی داده های یکنواخت و گاوسی بترتیب در اشکال (۴) و (۵) ملاحظه می گردد.

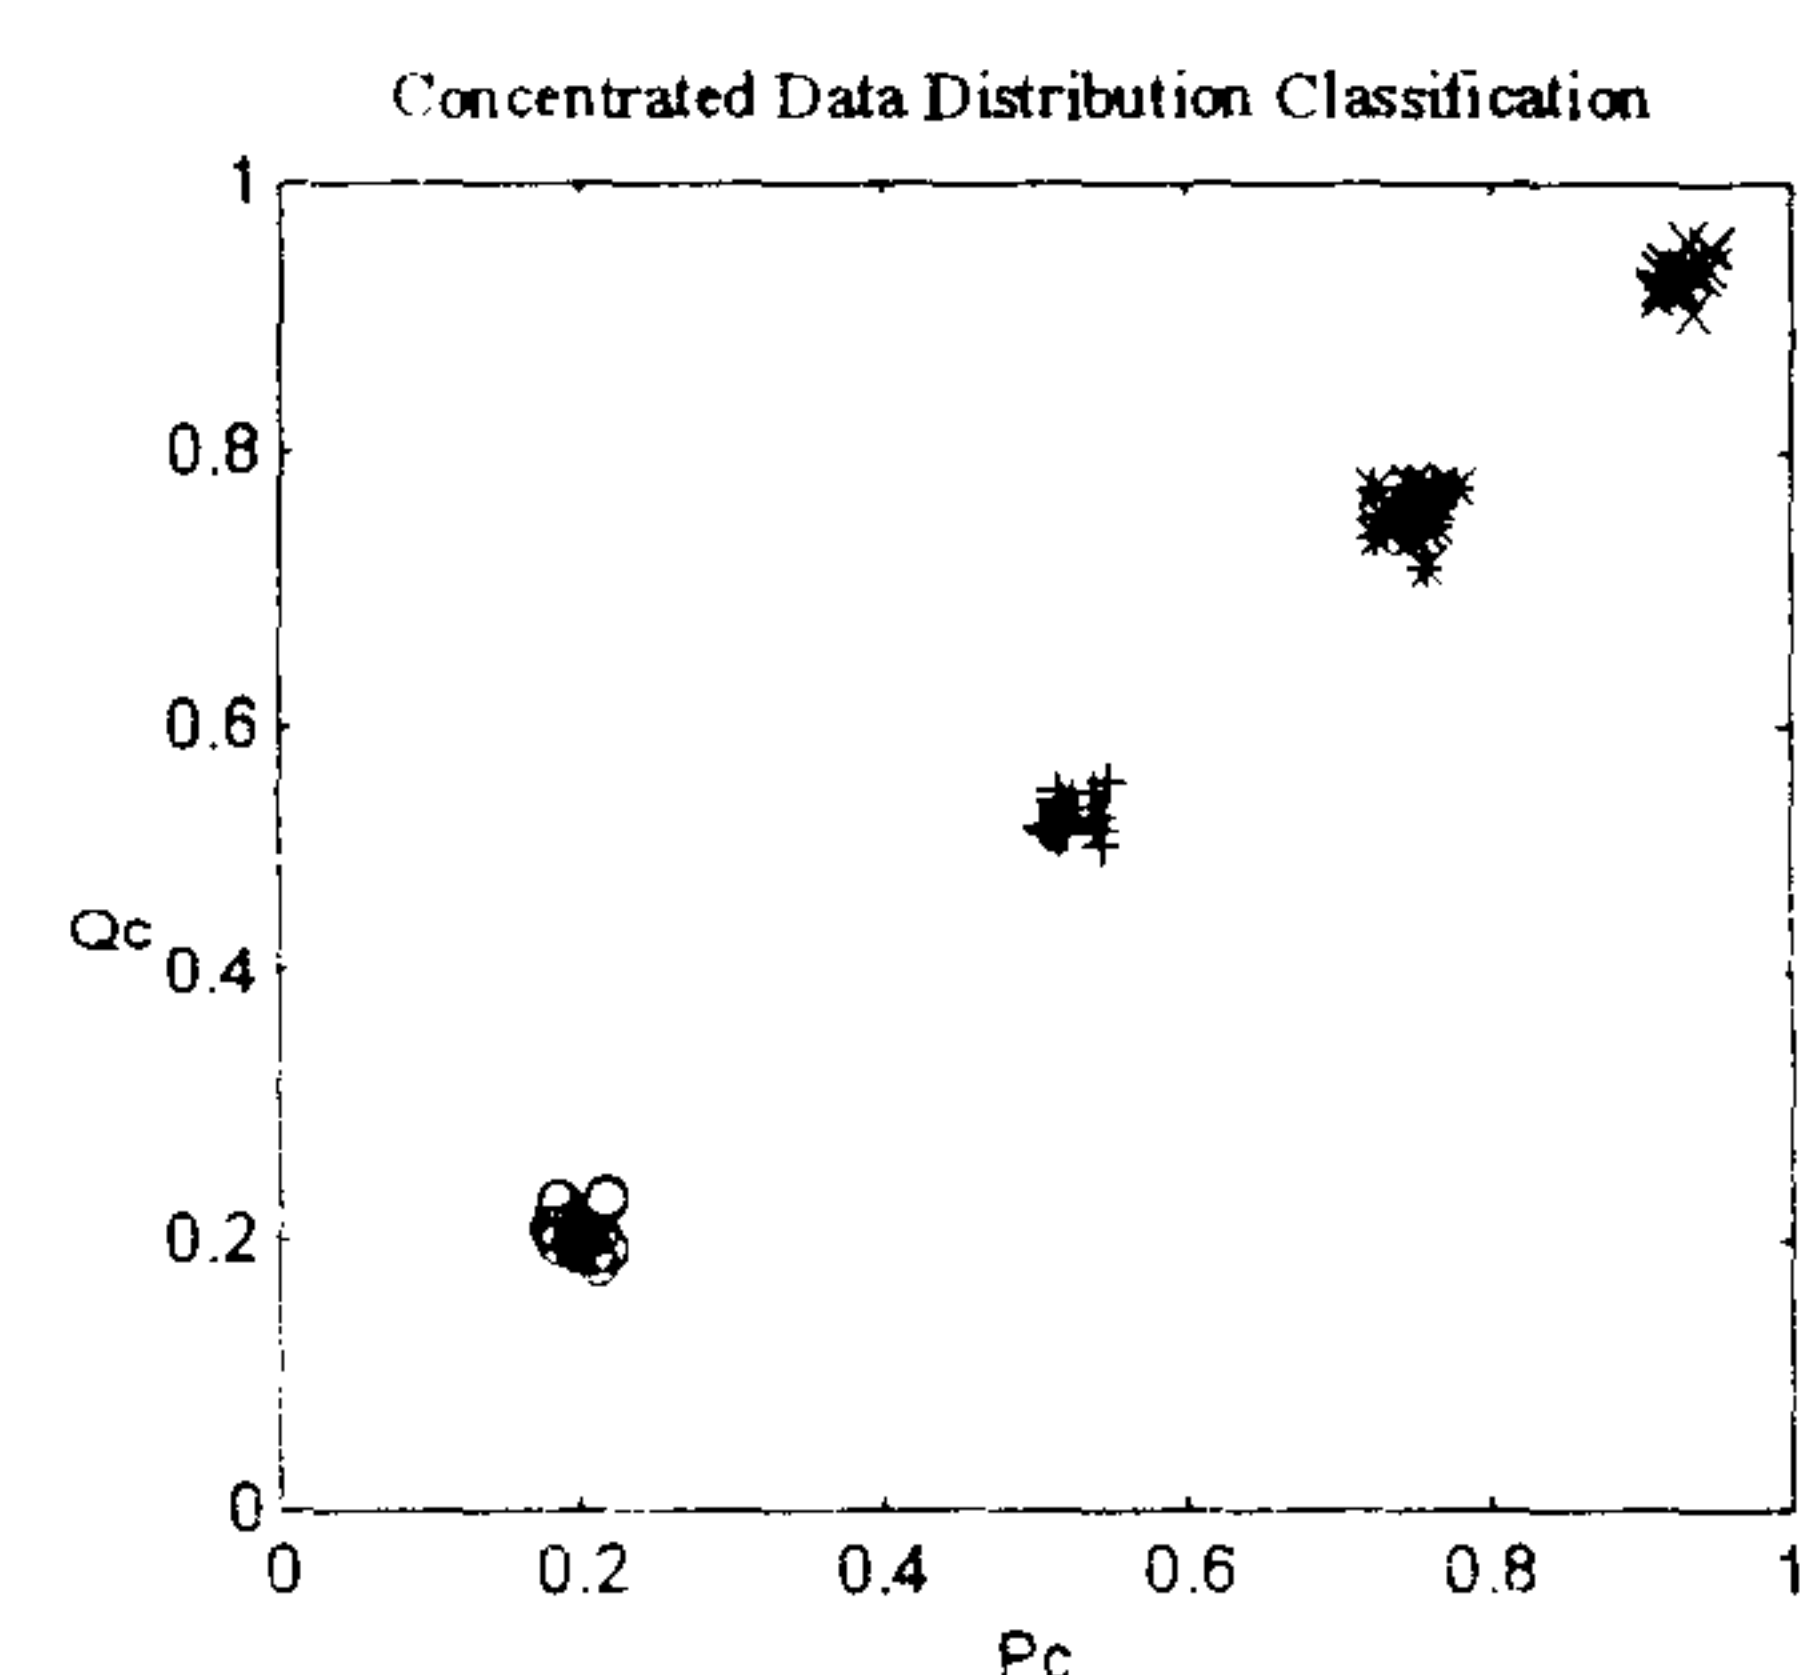
نگاشت همدیس

تقارن شعاعی شبکه عصبی RBF ایده تغییر شکل فضای کلاسه سازی را از فرم مربعی به فرم دایره ای مطرح می سازد و دو بعدی بودن این فضا و نیز موهوم بودن یکی از متغیرهای فضا (توان رأکتیو) ما را به استفاده از آنالیز مختلط رهنمون می سازد. نگاشتهای همدیس، توابع

ویا حتی با یک توزیع کاملاً یکنواخت به آن یاد داد. بعبارت روشنتر، شبکه عصبی پرسپترون چند لایه MLP یک شبکه "حساس به مرز" یا "مرز گرا" می باشد. این مطلب نیز در بخش پایانی نشان داده خواهد شد.



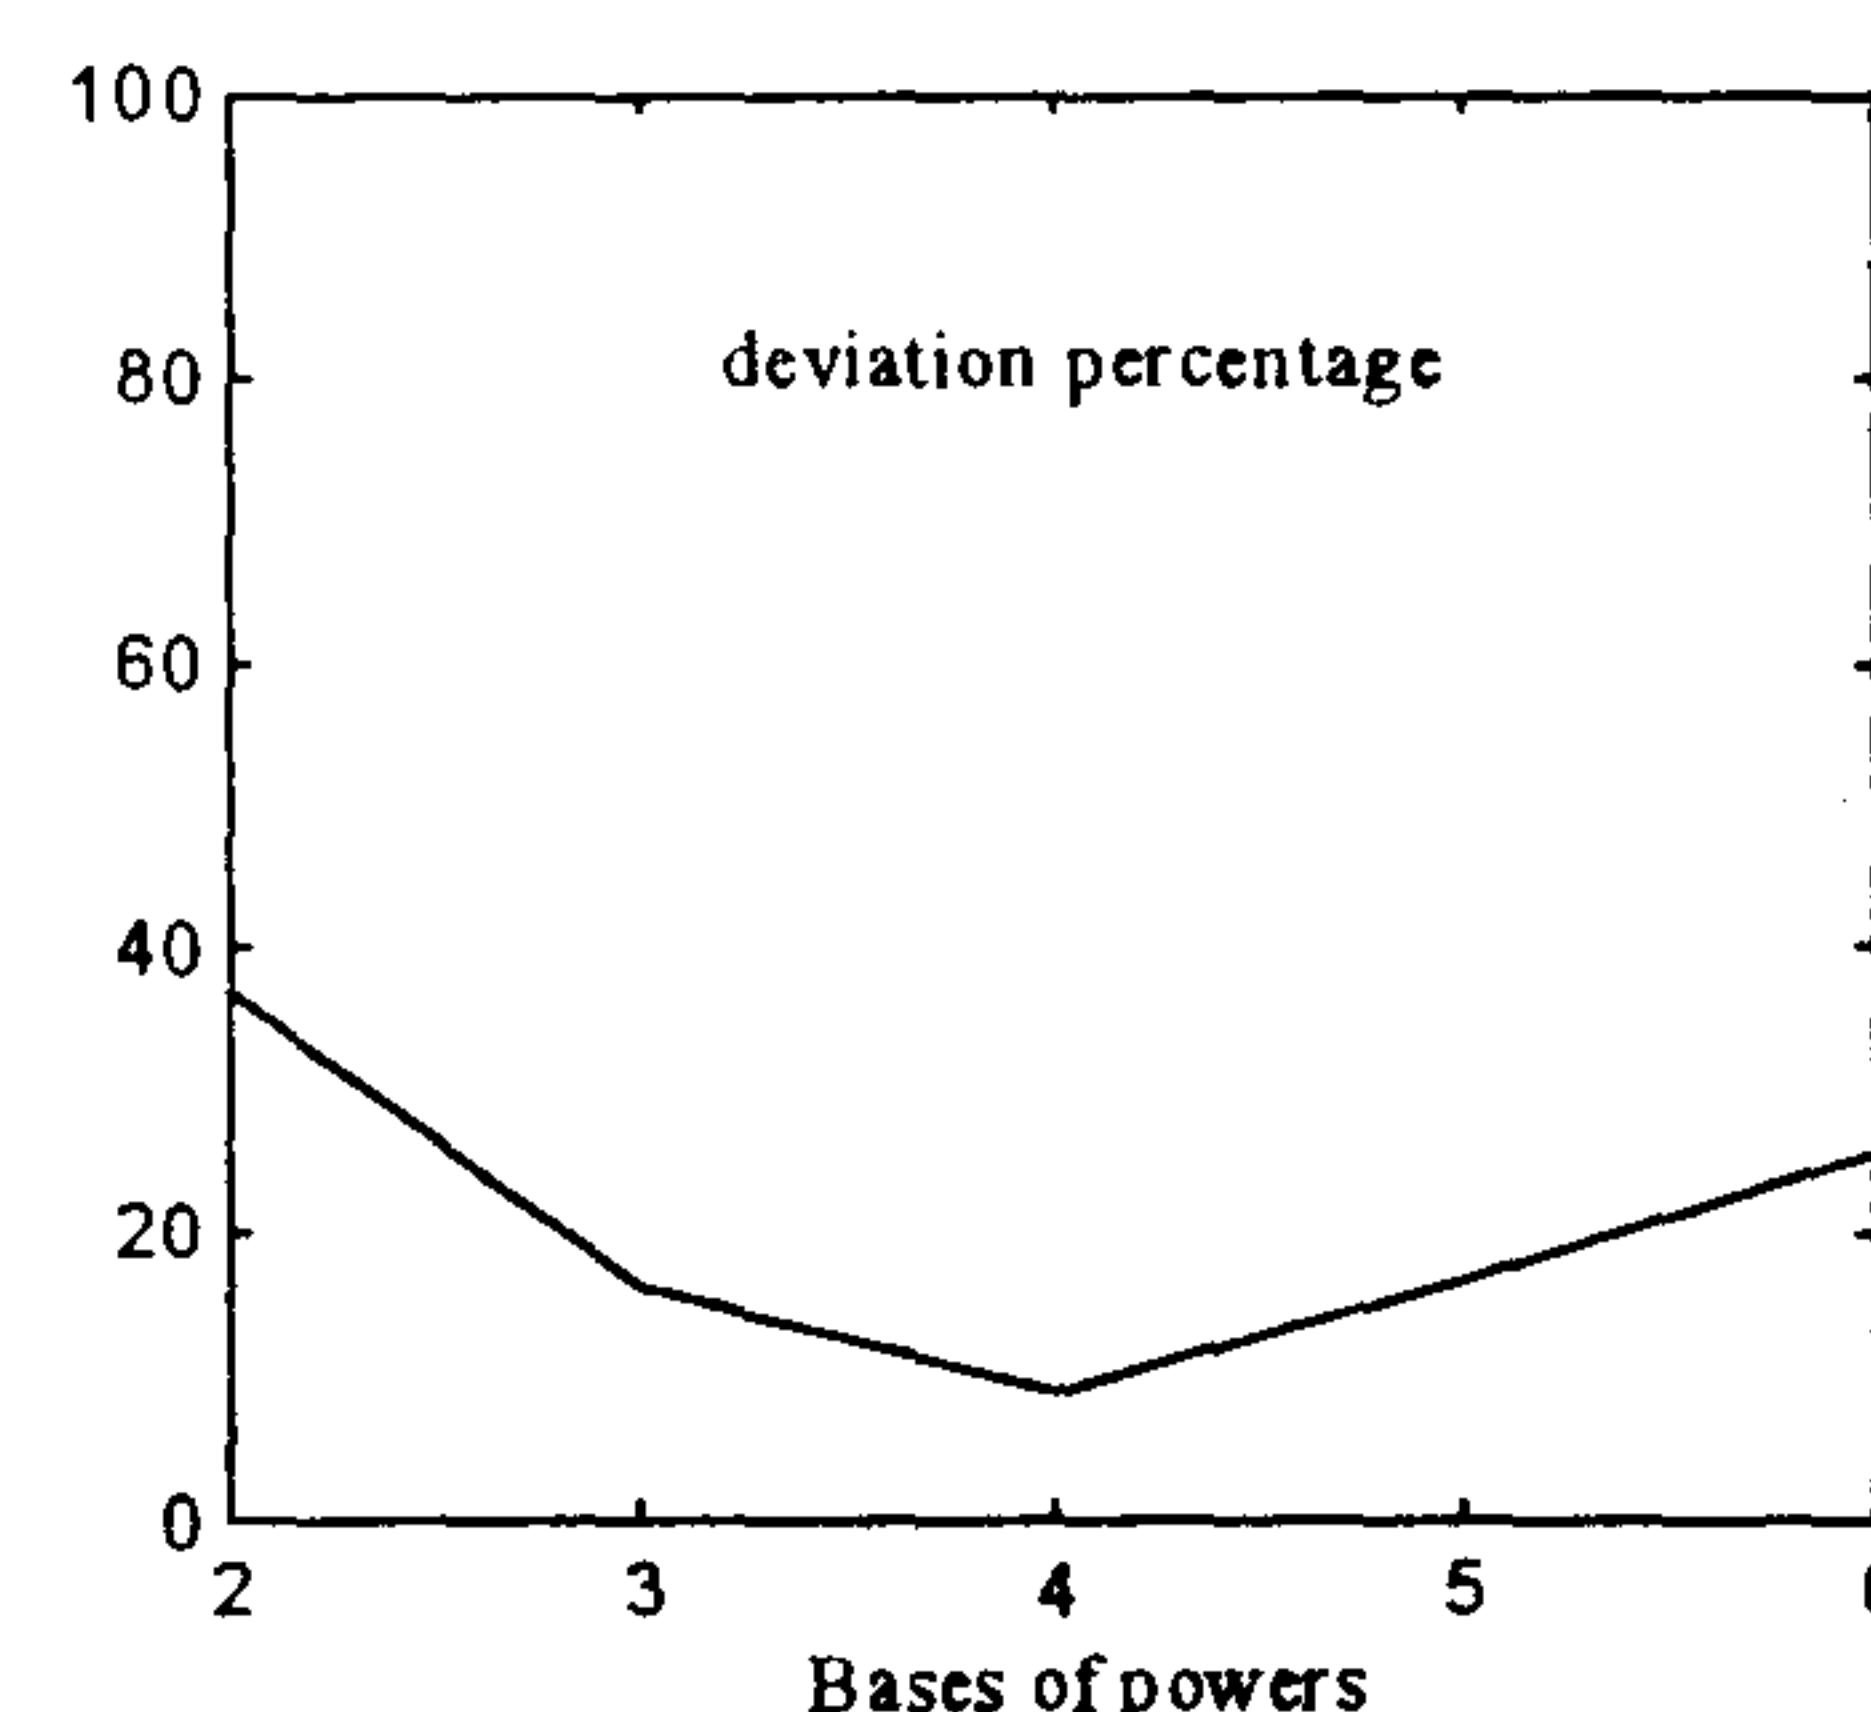
شکل ۱: سطوح بار با داده های توزیع شده یکنواخت.



شکل ۲: سطوح بار با داده های متمرکز یا گاوسی.

بنابراین، توزیع داده ها برای ۸۰ نمونه داده به دو صورت انجام می پذیرد:

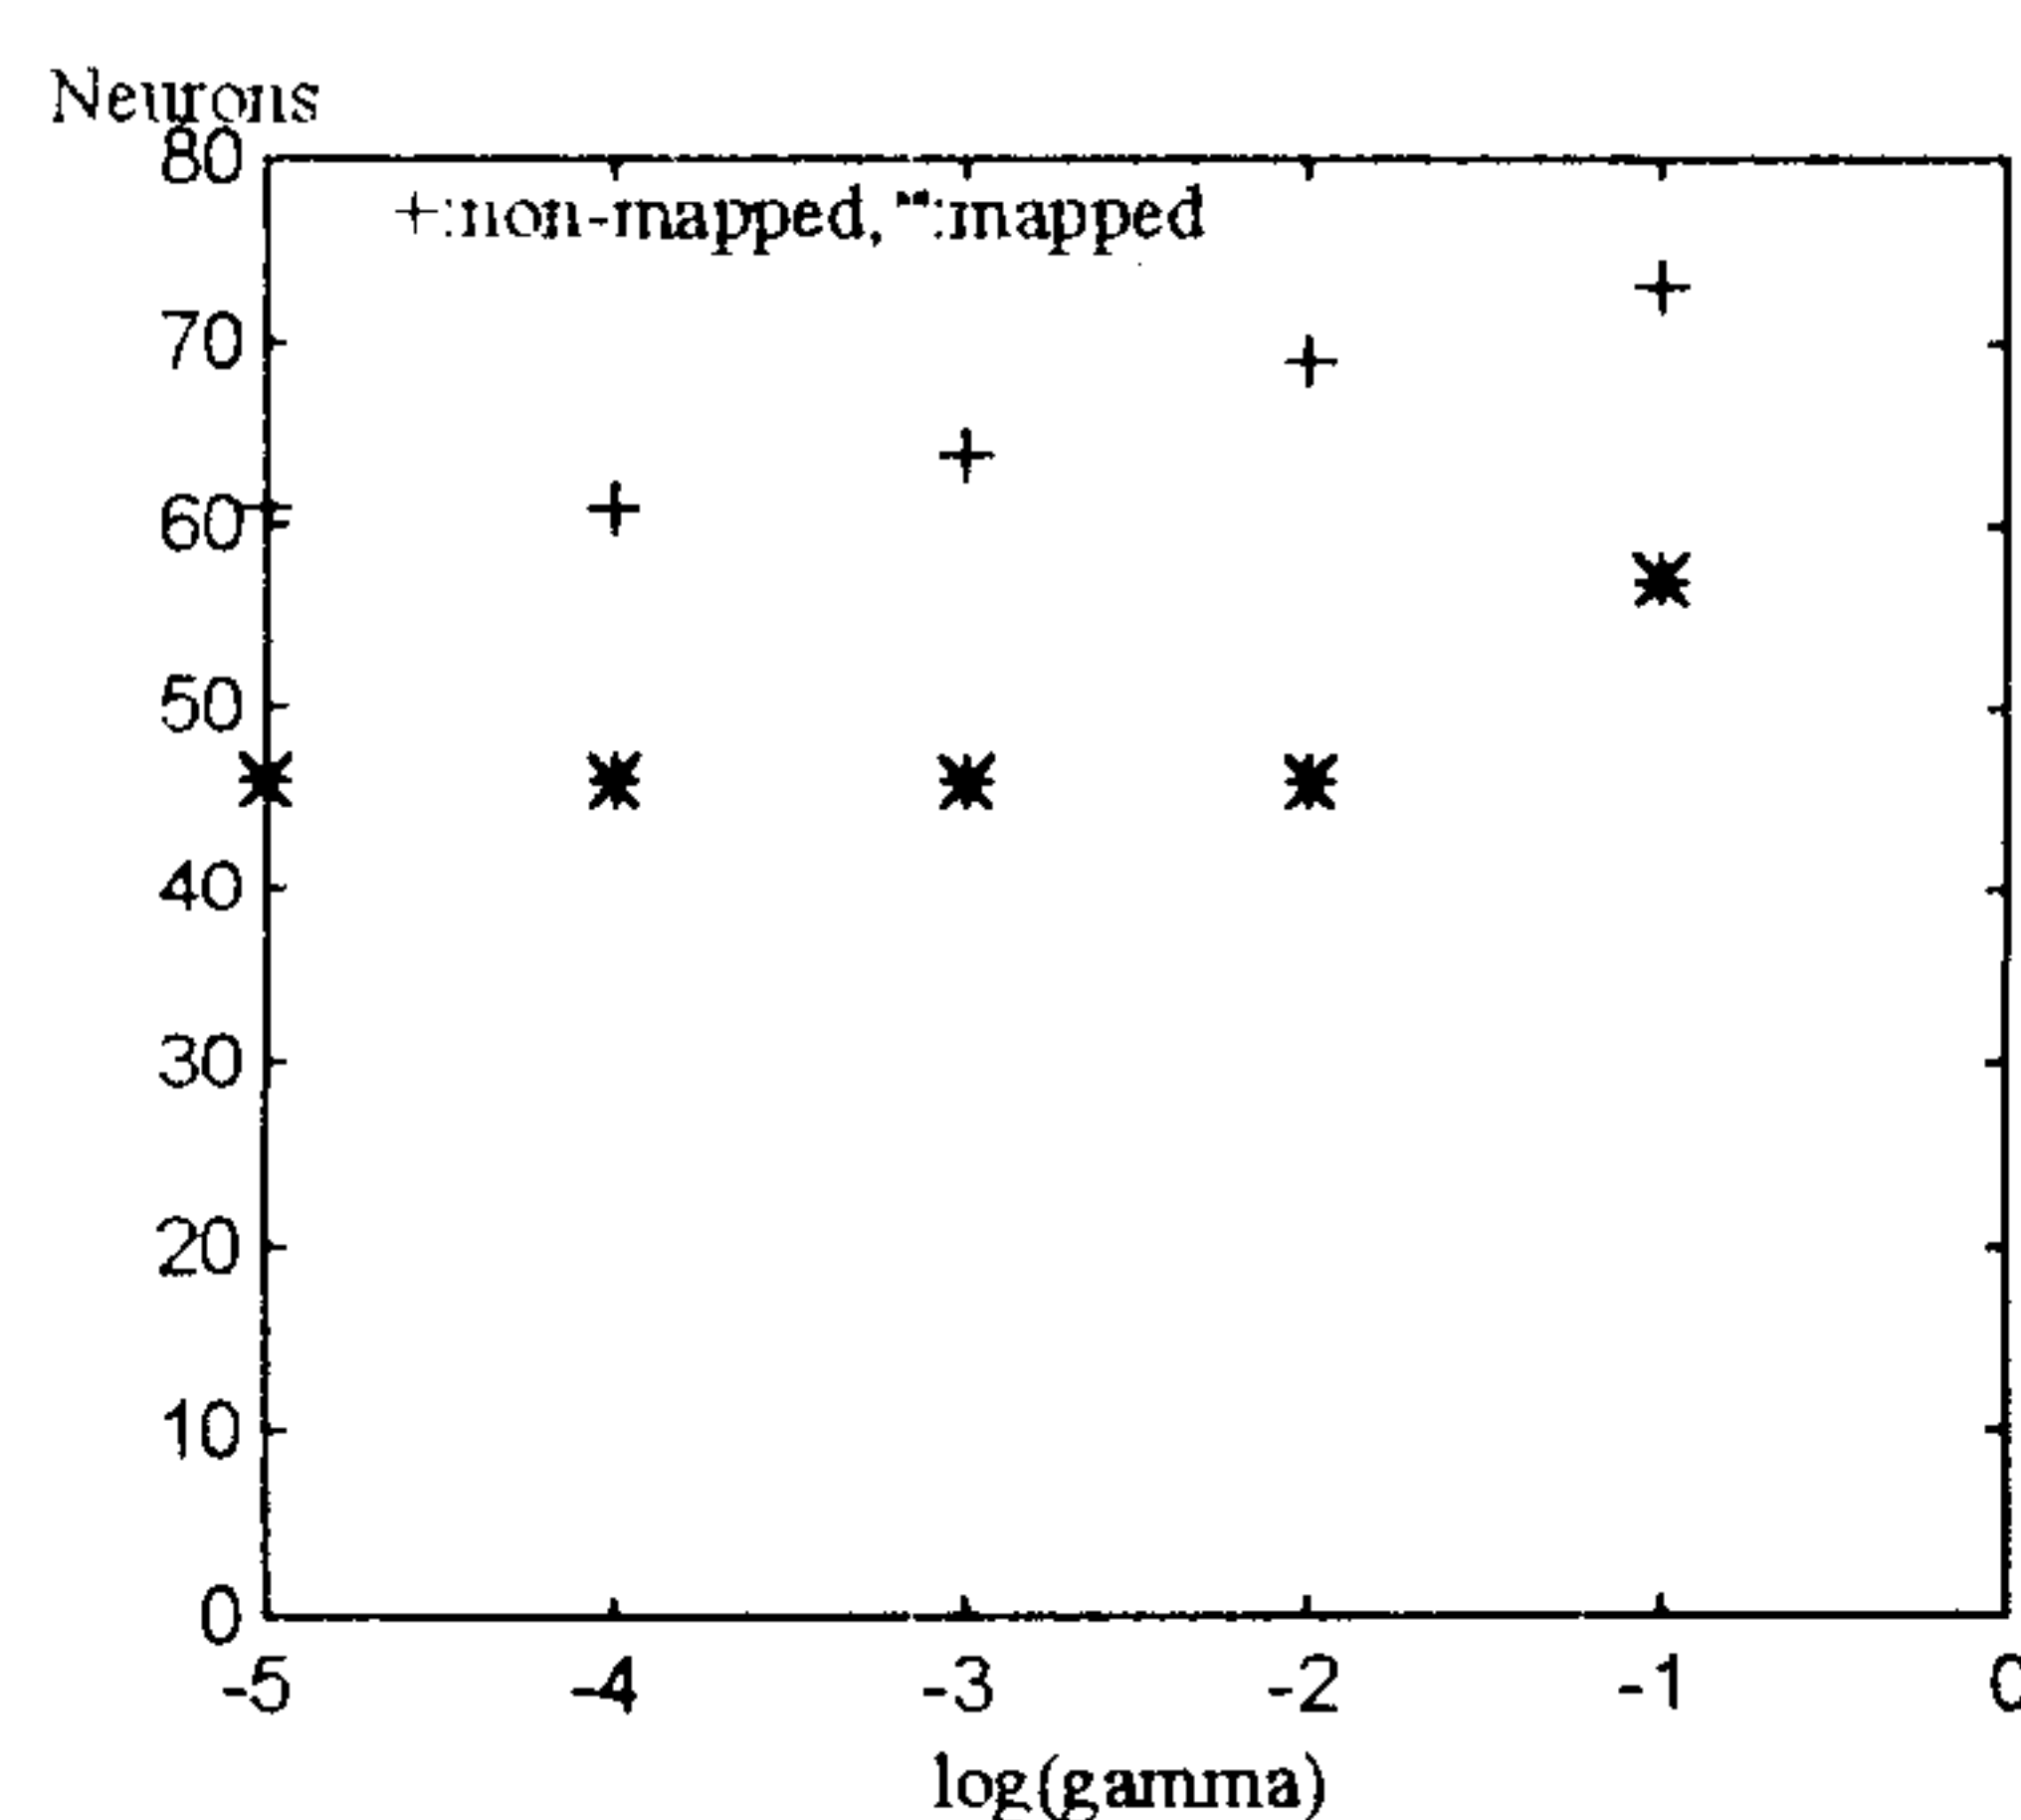
۱. توزیع داده های یکنواخت: داده ها بشکل یکنواخت در فضای کلاسه سازی توزیع می گردند. (شکل (۱))
۲. توزیع داده های متمرکز یا گاوسی: داده ها بشکل گاوسی حول مرکز هر کلاس در فضای کلاسه سازی توزیع می گردند. (شکل (۲))



شکل ۳: منحنی درصد انحراف نسبی بر حسب پایه های صحیح نگاشت نمایی.

راه حلی که به ذهن متبادر می گردد، این است که پهنای باند توابع گاوسی افزایش یافته تعداد آنان محدود گردد، زیرا همانگونه که اشاره رفت، در روشهای خوشه یابی، الگوریتم بطور بدون سرپرستی برای هر تجمع نمونه ها یک کلاس قائل می شود، حال اگر پهنای باند توابع گاوسی - که در شبکه های با تقارن شعاعی تعیین کننده شعاع کلاس های دایروی و یا بیضوی قرار داده شده است - بزرگتر گردد، کلاس ها بزرگتر شده و نمونه های بیشتری در خوشه ها قرار خواهند گرفت و در حالت حدی میتوان به تعداد مورد نظر کلاس ها نائل گشت. متأسفانه این کار منجر به مشکل بد حالتی ماتریس های خطا و یا مشکل رتبه (Rank) آنها می شود و الگوریتم آموزش واگرا می گردد.


از آنجا که فضاهای کلاسه سازی شبکه های با تقارن شعاعی فضاهای ابر بیضوی (و یا در شرایط تساوی پهنای باند توابع گاوسی نرون ها، ابر کروی) می باشد، ابر بیضوی (و یا ابر کروی) نمودن فضاهای کلاسه سازی میتواند راه حلی برای بهبود ویژگی های همگرایی برنامه های آموزش شبکه های با تقارن شعاعی باشد. لذا با استفاده از نگاشت همدیس، فضاهای مربعی شکل (۱) به فضاهای دایره ای متداخل شکل (۶) تبدیل شده و به شبکه عصبی آموخته می شوند.




شکل ۸: تعداد نرون های لازم برای یادگیری برحسب لگاریتم ضریب نویز (۷).
(+ : نگاشته نشده، * : نگاشته شده)

برای آموزش فضاهای دایره ای لازم است به داده های ورودی نویز افزوده گردد، بهمین جهت یک جمله نویز تصادفی با ضریب γ (برای کنترل اندازه نویز) به ماتریس داده های ورودی اضافه میگردد اثر این جمله نویز خارج ساختن سیستم از حالت موجبی^۱ صرف به سیستمی که تا حدودی ویژگیهای تصادفی^۲ دارد میباشد و اثر معجزه

مختلطی هستند که یک ناحیه را در فضای دو بعدی مختلط به ناحیه ای در فضای مختلط دیگری می نگارند.



شکل ۶: فضای نگاشته شده دایره ای برای داده های یکنواخت.



شکل ۷: فضای نگاشته شده دایره ای برای داده های گاوسی.

برای انجام این نگاشت چهار نامزد $\frac{(z-1)}{(z+1)}$


، $\frac{(i-z)}{(i+z)}$ و $\frac{(\cos(z)-1)}{(\cos(z)+1)}$ که همگی

توانایی تبدیل نواحی مربعی به دایره ای را دارند، مورد بررسی و مقایسه قرار گرفته اند و نهایتاً نگاشت $f(z) = (\exp(z))$ انتخاب شده است [۳]. اشکال (۶) و (۷) بترتیب کلاس های نگاشته شده دایره ای را برای داده های یکنواخت و داده های گاوسی نشان می دهند.

کلاسه سازی با RBF

ابتدا سعی شده داده های یکنواخت شکل (۱) به یک شبکه عصبی RBF آموزش داده شوند از آنجا که داده ها خیلی پراکنده میباشند و شبکه عصبی RBF (که برای آموزش لایه پنهان خود از الگوریتم بدون سرپرستی K-means Clustering بهره می برد) برای یادگیری هر تک نمونه یک نرون قرار می دهد، یعنی حدود ۸۰ نرون گاوسی لازم می باشد و قدرت تعمیم شبکه بسیار بد است.

یادگیری این داده ها کافیهست. ضمن اینکه این داده ها برای یادگیری نیازی به نویز نیز ندارند.




شکل ۱۰: منحنی خطای یادگیری شبکه RBF با نمونه های گاوسی بر حسب تعداد تکرار.

در نهایت، شبکه RBF آموزش یافته با داده های خوشه ای (متمرکز)، دارای دو ورودی، ۱۴ نرون گاوسی میانی و دو نرون خطی خروجی می باشد که از نظر بعد نسبت به شبکه آموزش داده شده با داده های یکنواخت بسیار بهتر و کارایی آن نیز بسیار برتر است. این شبکه از نظر قدرت تعمیم نیز بسیار بهتر از شبکه آموزش دیده با داده های یکنواخت عمل می کند و می تواند به دقت کافی داده های مجموعه آموزشی و آزمون را پاسخ بدهد. علت این امر را میتوان در ویژگی گاوسی تابع انتقال شبکه های RBF جستجو نموده و یافت. نتیجه اینکه "شبکه RBF یک شبکه عصبی کلاسه ساز" مرکزگرا می باشد و برای آموزش آن باید روی مرکز کلاسه ها تأکید گردد.

کلاسه سازی با MLP

برای آموزش شبکه پرسپترون چند لایه (MLP) از الگوریتم آموزشی پس انتشار خطا استفاده شده است. همچنین بمنظور بررسی و بهبود توانمندی شبکه آموزش داده شده در پاسخگویی به ورودی های آموزش داده نشده به آن (تعمیم) از روش اعتبار متقابل^۱ [۶، ۲] بهره برده شده است، بدین ترتیب که بیست درصد از نمونه ها (داده ها) بصورت اتفاقی انتخاب و بعنوان مجموعه آزمون^۲ و باقیمانده بعنوان مجموعه آموزشی^۳ در نظر گرفته میشود و یادگیری تا زمانی ادامه می یابد که خطای آموزش (ETm) و خطای آزمون (Etst) هر دو روی به کاهش دارند. مزیت این روش، جلوگیری از مشکل آموزش بیش از حد^۴ شبکه (که از دیدگاه گرافیکی بمعنای نزول منحنی Etst همزمان با صعود منحنی Etst است) می باشد.

آسایی در یادگیری شبکه دارد. بدون نویز مشکلاتی نظیر تقسیم بر صفر و بدحالتی ماتریس های خطا و ضرایب بوجود می آید. کاهش ضریب نویز ۷ تعداد نرون های لازم در لایه گاوسی را کاهش می دهد، اما از حدی کمتر نمی توان ضریب نویز را کاهش داد. این روند در شکل (۸) ملاحظه میگردد. همچنین در این شکل مشاهده می شود که انجام نگاشت همدیس اثر قابل ملاحظه ای در کاستن از تعداد نرون های گاوسی لازم برای آموزش شبکه عصبی داشته است. از دیدگاه ترمودینامیکی می توان اعمال نویز به ورودی یک شبکه عصبی تحت آموزش را معادل ورود انرژی حرارتی به یک شبکه کریستالی در حال ایجاد (سرد شدن) مثل آبکاری فولاد و یا اعمال اندکی آنتروپی به یک سیستم در حال نیل به تعادل که در دام یک تعادل نسبی (موضعی) گیر کرده است، دانست. [2,6]



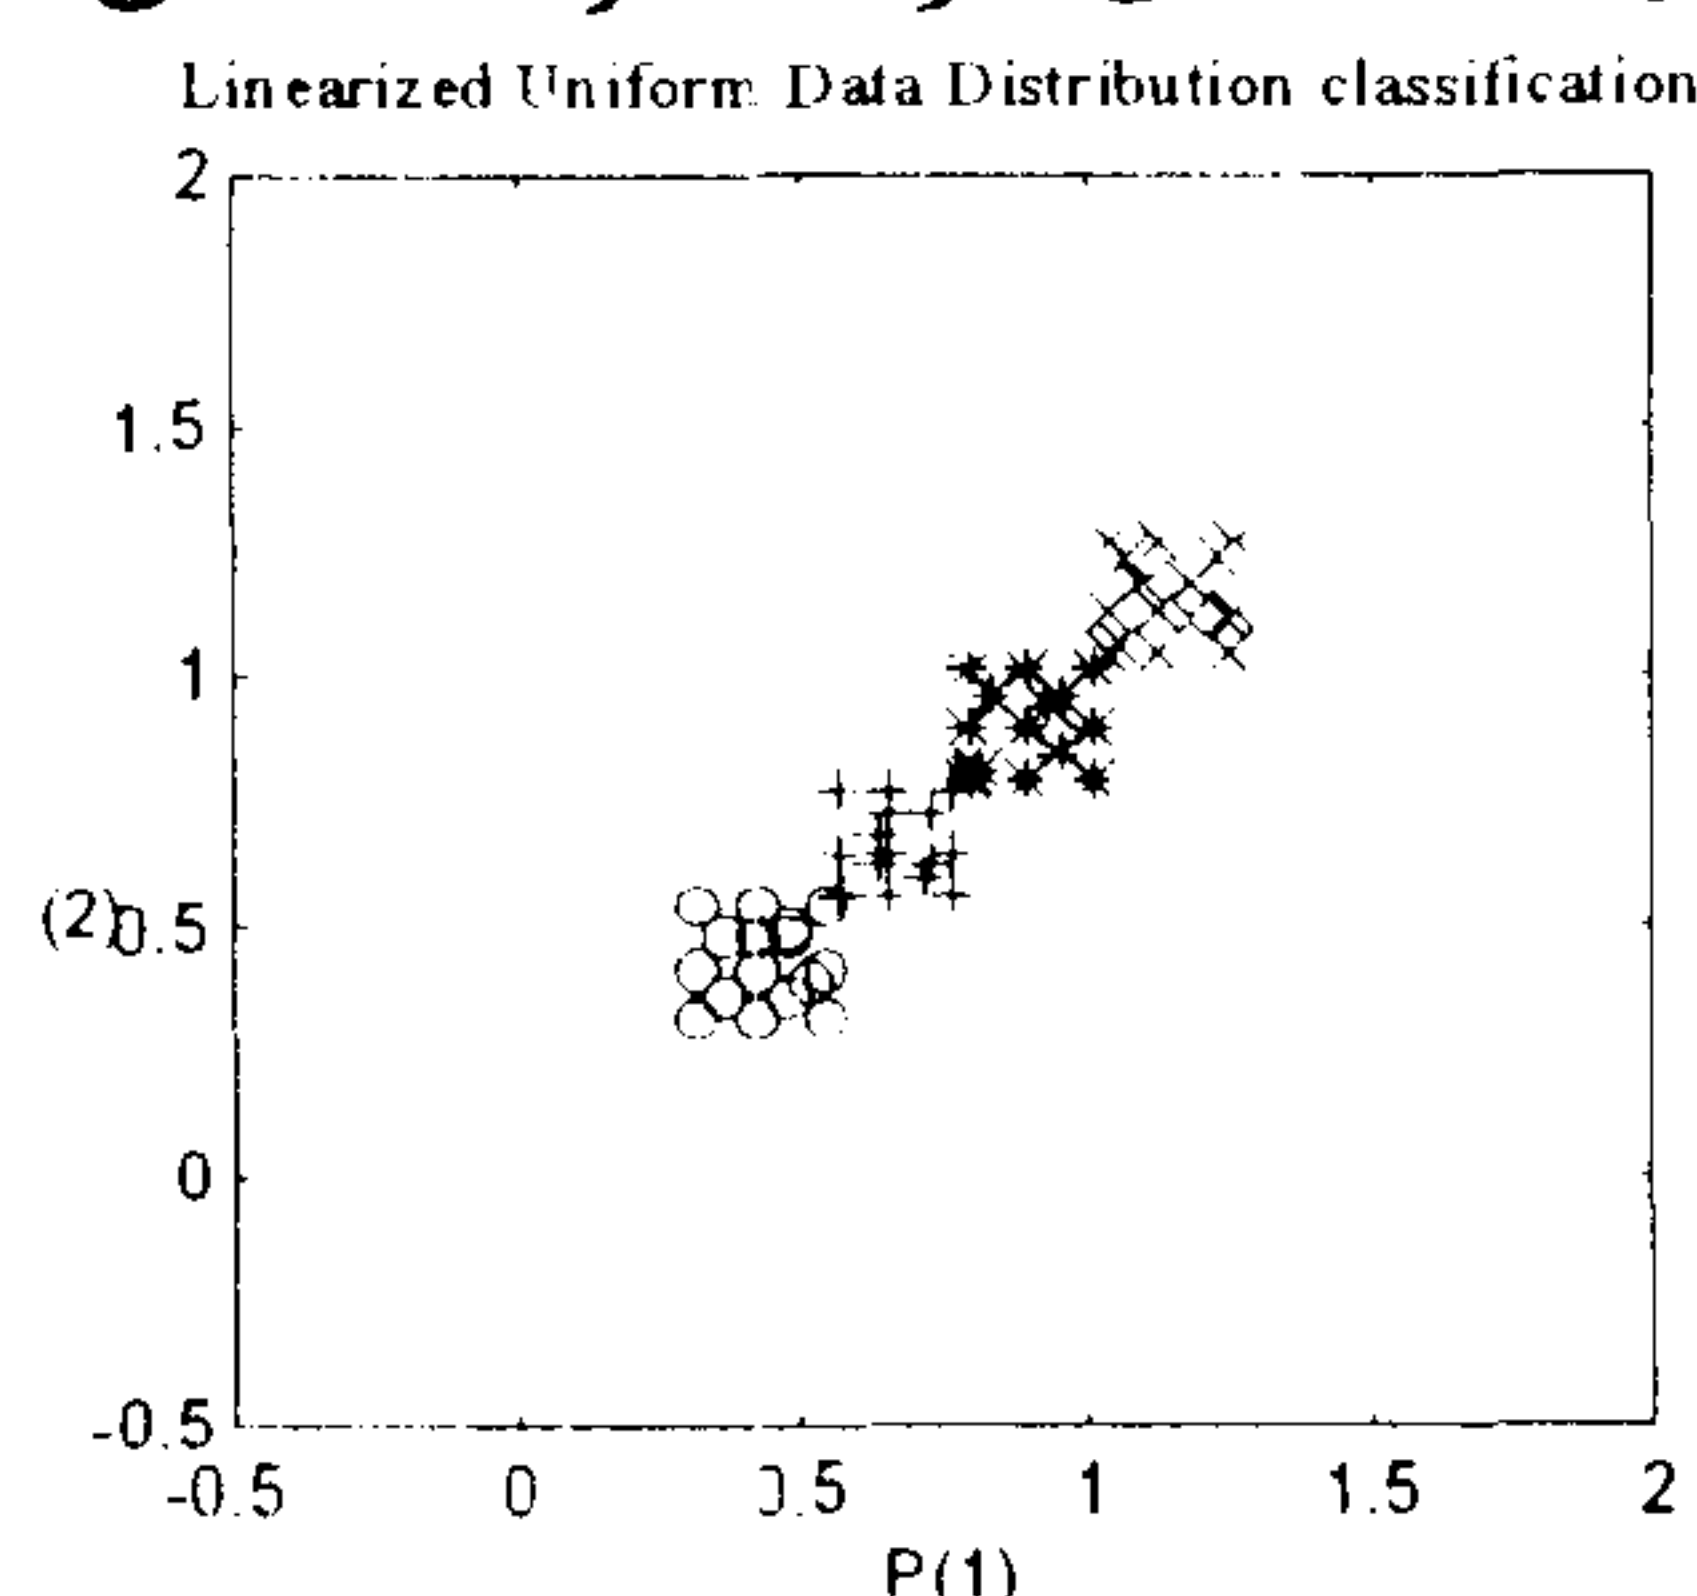
شکل ۹: منحنی خطای یادگیری شبکه RBF با نمونه های یکنواخت بر حسب تعداد تکرار.

همانگونه که در شکل (۸) ملاحظه می گردد، با انجام نگاشت همدیس تعداد نرون های لازم به ۵۰ نرون کاهش یافته که پیشرفت خوبی است (شکل (۹))، اما در این حالت نیز مشکل قدرت تعمیم شبکه باقیست و هنوز هم افزایش پهنای باند نرون های گاوسی از حد معینی برنامه دچار مشکلات محاسباتی غیر قابل حلی می گردد و خطای یادگیری از میزان معینی کمتر نمی شود. در اینجا روشهای یادگیری مانند LVQ و Kohonen نیز آزموده شده اند و پاسخ قابل قبولی ارائه نموده اند.

برخلاف داده های با توزیع یکنواخت، داده های خوشه ای (متمرکز) که مقیاس و نگاشته نشده اند یعنی داده های شکل (۲) در یادگیری توسط شبکه RBF بهبود امیدوارکننده ای نشان می دهند. این داده ها با خطای کمتر از یک درصد توسط ۱۴ نرون لایه میانی آموخته می شوند (شکل (۱۰)) و این در حالی است که اگر خطای ده درصد رضایت بخش باشد، تنها دونرون لایه میانی برای

شبکه با خروجی چهارگانه (توپولوژی سوم) کارایی آموزشی و تعمیم بسیار بهتری از دو شبکه دیگر دارد و همین دلیل برای انتخاب این نوع لایه خروجی حجت می باشد. در مورد داشتن توجیه فیزیکی در نوع اول باید گفت که این امر برای یک شبکه عصبی مصنوعی که دارای چهار ویژگی مهم غیرخطی بودن، قدرت یادگیری، کشف خواص پنهان کلاس ها از مثال های متعدد و عدم نیازمندی به مدل دقیق فیزیکی سیستم می باشد، نسبت به سایر عوامل، اهمیت کمتری در تصمیم گیری دارد.

برای تصمیم گیری در مورد تعداد نرون های لایه پنهان، ترکیبی از دو روش مشهور Cascade Correlation بر مبنای رشد شبکه و هرس یا پیرایش^[۶، ۲] بمعنای حذف ضرایب و نرون های با کمترین مشارکت در تولید خروجی بکار گرفته شده است و پس از انجام بررسی های لازم نتیجه گرفته شده که شبکه عصبی مصنوعی پرسپترون سه لایه ای با دو گره در لایه ورودی، سه نرون سیگموئید در لایه میانی و چهار نرون سیگموئید در لایه خروجی برای اینکار بهینه است، یعنی $2 \times 3 + 3 \times 4 = 18$ وزن و $3 + 4 = 7$ بایاس باید در شبکه تعیین شود تا بتواند از پس وظیفه کلاسه سازی و تخمین سطح بار نواحی برآید. ابعاد بسیار کوچک این شبکه عصبی در مقایسه با شبکه های مشابه قابل توجه است: در کاربردی مشابه [۱۲] تعداد نرون های لایه پنهان ۲۴ عدد و در یک مقاله دیگر [۸] تعداد نرون های لایه پنهان هفت عدد ذکر گردیده است و این در حالی است که شبکه عصبی MLP طراحی شده در این مقاله فقط سه نرون لایه پنهان دارد. از طرف دیگر، همانگونه که در بخش مثال عملی ملاحظه خواهید نمود، این شبکه دارای قدرت یادگیری و تعمیم صد در صد برای داده های در محدوده کلاس ها است.



شکل ۱۱: فضای کلاسه سازی خطی شده.

به این شبکه عصبی سه سری مجموعه آموزشی یاد داده شده است: نمونه های سطوح بار با داده های توزیع

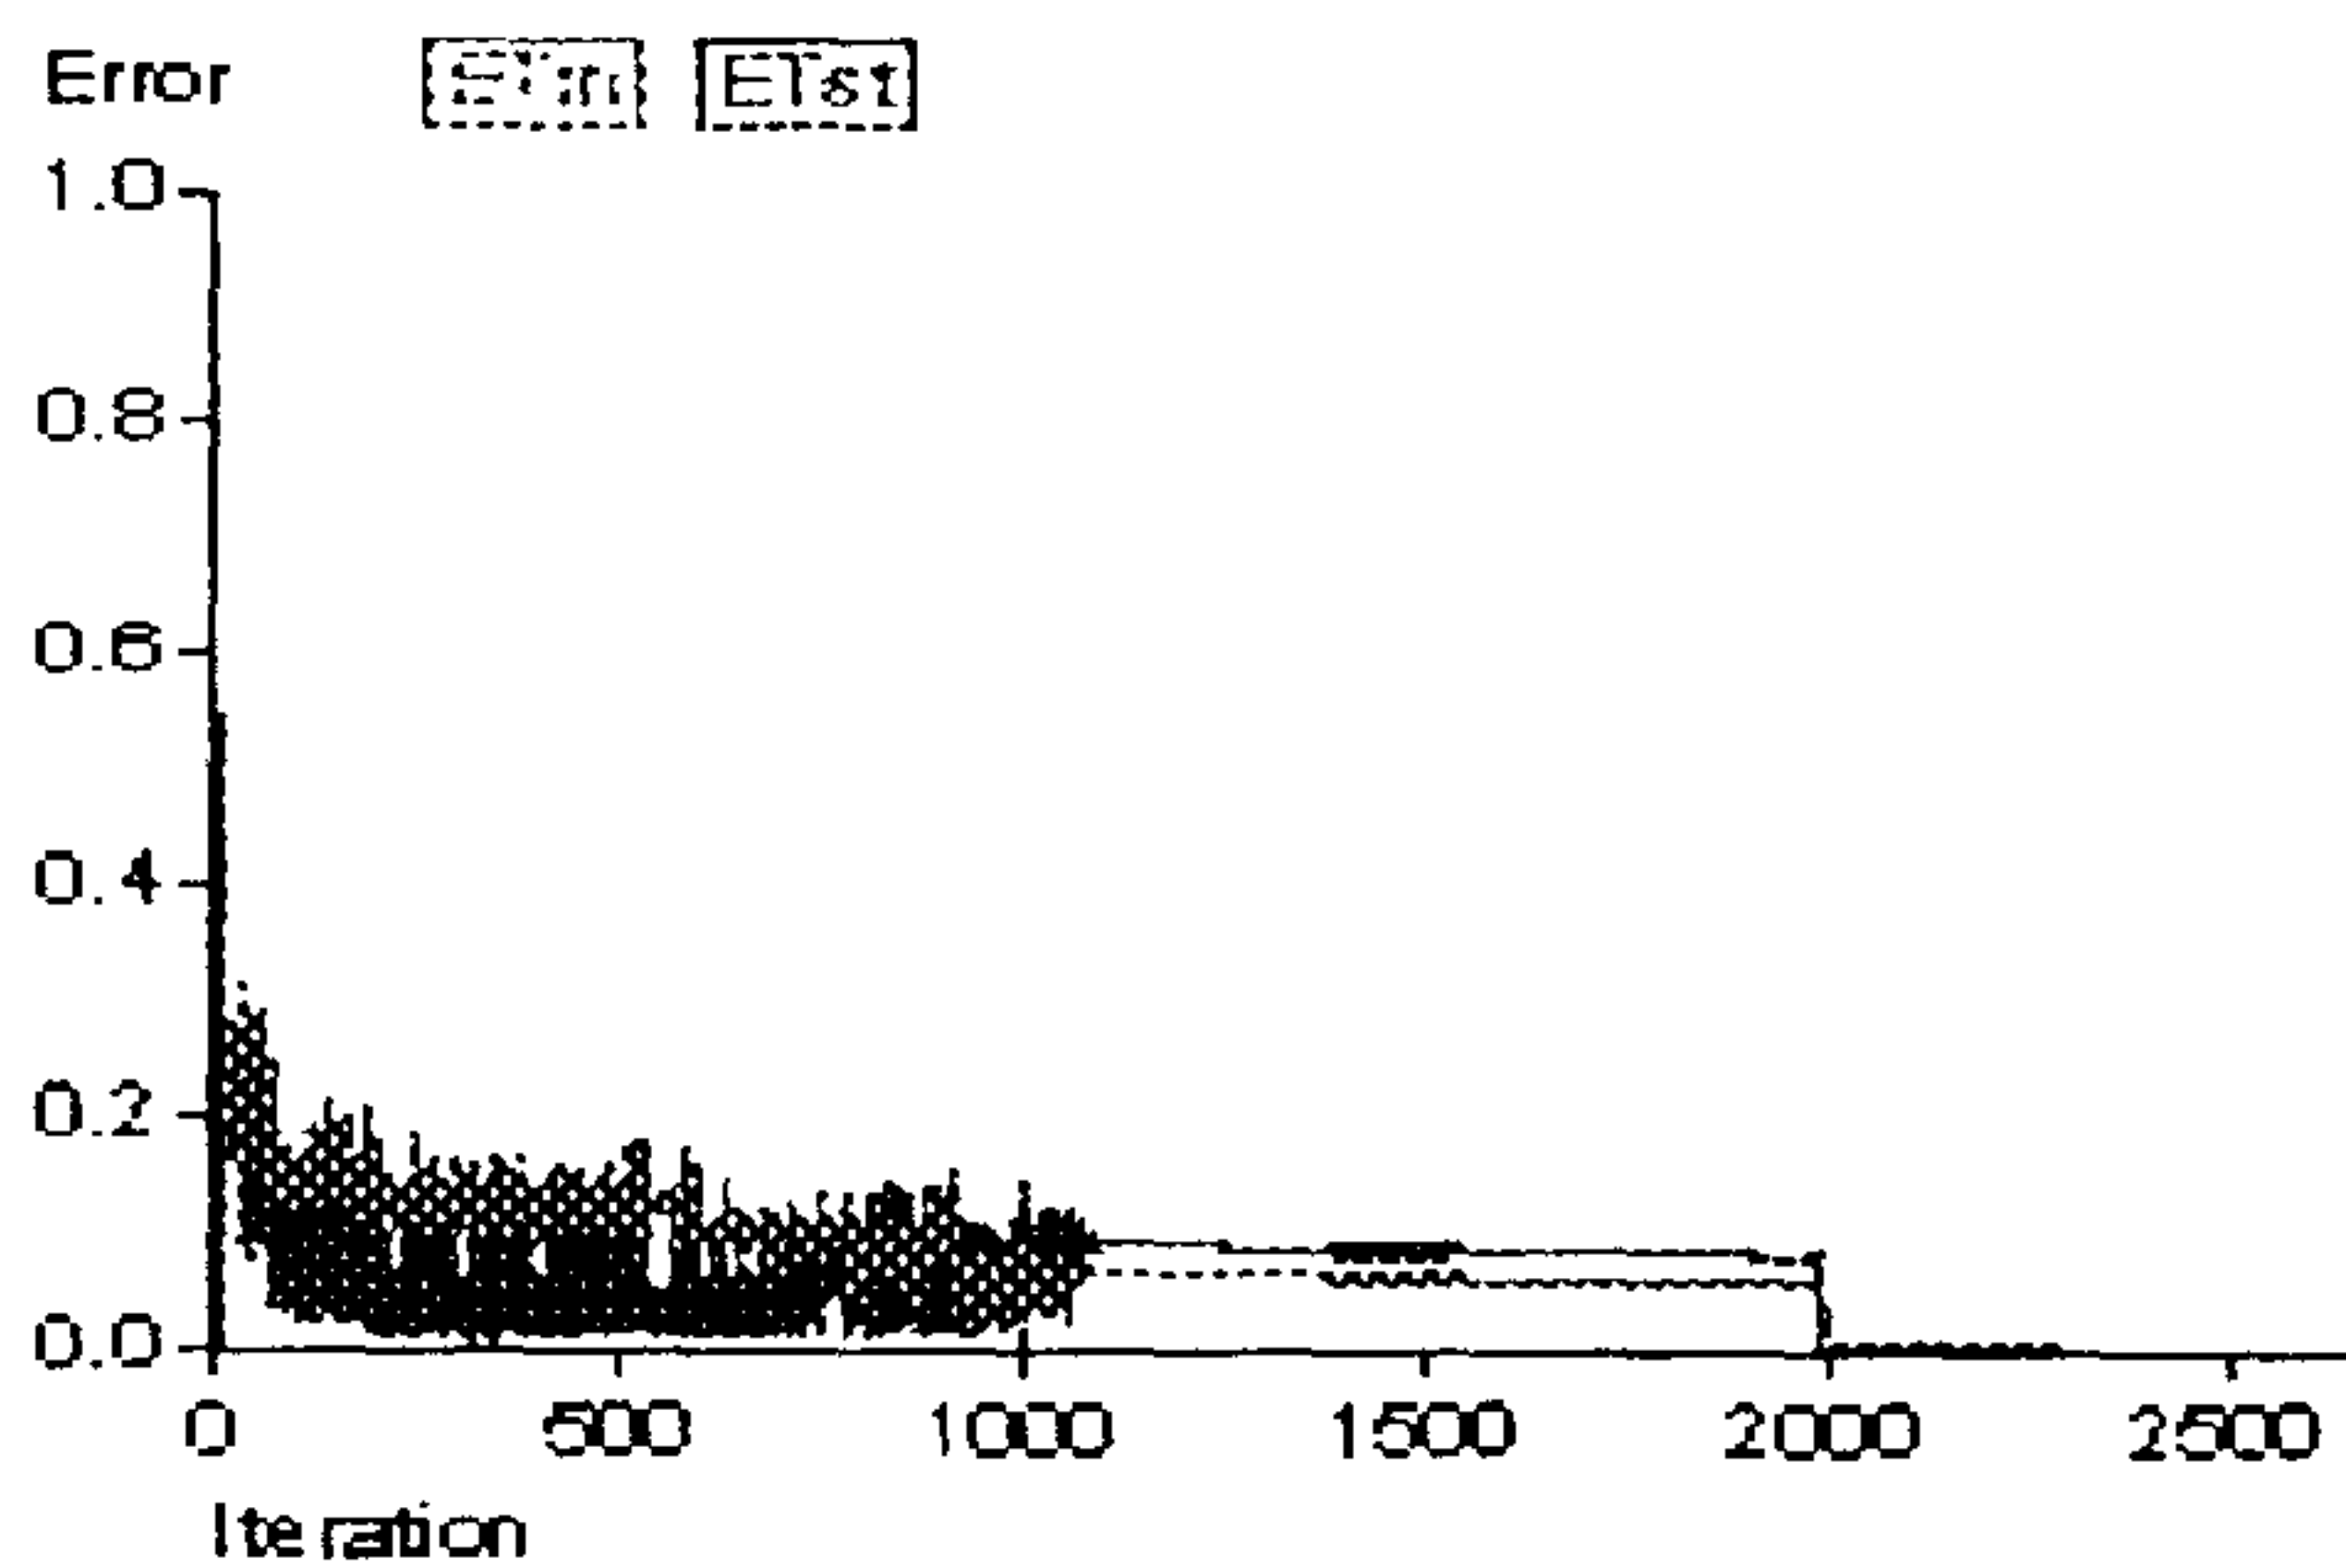
بدلیل داشتن دو ورودی، شبکه عصبی مورد نظر باید دارای دو واحد ورودی باشد. برای طراحی لایه خروجی سه توپولوژی اساسی را میتوان پیشنهاد نمود:

۱. یک نرون خطی که چهار عدد یک تا چهار را تولید مینماید.
۲. دو نرون غیر خطی که بصورت کد شده دودویی چهار عدد خروجی را تولید می نمایند.
۳. چهار نرون غیر خطی که بصورت One Hot، فقط یکی از آنها که بیشترین مقدار را داراست کلاس خروجی را نشان می دهد.

مزیت شکل اول، داشتن توجیه فیزیکی می باشد و شبکه می تواند از منطق پنهان مستتر در ساختار خویش برای آموزش بهتر مجموعه آموزشی استفاده نماید. از طرف دیگر، برای داده های جدید، ممکن است خروجی عدد صحیح نباشد (مثلاً ۶/۵۴ یا ۳/۵۱) و تصمیم گیری در مورد کلاس (حالت) سیستم را مشکل نماید. مشکل دیگر این نوع توپولوژی، قابلیت کم تحمل خطا در آن می باشد، بدین معنا که مثلاً یک خطای ۰/۷ در توپولوژی اول می تواند نتیجه را عوض کند اما در توپولوژی سوم حتی اگر خروجی یکی از نرون ها بجای صفر، ۰/۷ باشد، باز هم نرونی که باید فعال باشد، بدلیل داشتن خروجی نزدیک به یک، بخاطر بزرگتر بودن سطح فعالیتش بدرستی نشان دهنده سطح بار (حالت) واقعی خواهد بود.

موضوع دیگری که در برخی از متون علمی شبکه های عصبی بعنوان یک پارامتر تصمیم گیری در مورد توپولوژی شبکه ذکر شده [۹، ۲] ابعاد فضای نگاشت خروجی است. بدیهی است که فاصله کلاس ها در یک فضای خروجی چهار بعدی، خیلی بیشتر از یک فضای یک بعدی است و این امر می تواند دلیلی برای دقت بیشتر در توپولوژی سوم باشد. شاید بتوان گفت، این مطلب بیان دیگر و یا توجیه فیزیکی-هندسی مسأله قابلیت تحمل خطا است. و اما یک دیدگاه دیگر در این مورد این است که توپولوژی های با نرون کمتر، بدلیل ابعاد کوچکتر، تعداد کمتر وزنها و کوچکتر شدن ابر فضای بهینه سازی می تواند منجر به بهینه های موضعی کمتری شود و این مزیتی برای توپولوژی اول است. همچنین نیاز به یک رمزگشایی از ایرادهای توپولوژی دوم است.

در پایان و مهمتر از هر تعبیر تئوری و فلسفی فیزیکی دیگر، تجربه و بررسیهای متعدد عملی نشان میدهد که



شکل ۱۳: منحنی خطای یادگیری شبکه MLP برای داده های نگاشته شده.

به بیان ریاضی، در مورد خاص این نگاشت که بصورت $f(P) = 4^P$ می باشد، داریم:

$$\Delta f(P) = f(p + \Delta P) - f(p) \approx \frac{df(p)}{dp} \cdot \Delta p \quad (1)$$

$$\Delta f(P) = (\ln 4) \cdot (4^P) \cdot \Delta P \quad (2)$$

تغییر در اندازه تابع برای مقادیر مختلف p و یک مقدار Δp بسیار متفاوت است. مثلاً برای $p_1 = 0.2$ ، $p_2 = 0.9$ و $\Delta p = 0.1$ داریم:

$$\frac{\Delta f(P_2)}{\Delta f(P_1)} = \frac{0.483}{0.183} \approx 2.64 \quad (3)$$

ملاحظه می گردد که بازای یک تغییر یکسان در توان در دو نقطه مختلف تغییر ایجاد شده در مقدار نگاشت خیلی متفاوت است (نسبت ۲/۶۴) در حالی که اگر تبدیل خطی بود این نسبت یک می بود. علت این امر ثابت نبودن ضریب حساسیت تبدیل نسبت به متغیر آن میباشد:

$$S_p^f = p \cdot \ln 4 \approx 1.3863p \quad (4)$$


یعنی ضریب حساسیت بین ۰ و ۱/۳۸۶۳ تغییر می نماید که این امر همانگونه که ذکر شد منجر به بهم خوردن ضرایب حساسیت اولیه کلاس (حالت) نسبت به متغیرهای حالت سیستم و در نتیجه بهم خوردن منطق پنهان مستتر در مسأله کلاسه سازی می گردد و بهمین دلیل خطی سازی فضای کلاسه سازی با استفاده از یک نگاشت غیر خطی بجای بهبود یادگیری آنرا مشکلتر نیز

شده یکنواخت (شکل (۱))، نمونه های نگاشته شده همدیس با تابع نگاشت نمایی (یعنی نمونه های دایره ای شکل (۶)) و فضای خطی شده مربعی که همان نمونه های شکل (۱) تحت نگاشت 4^p ، $\frac{0.25}{0.79}$ ، $\frac{0.25}{0.79}$ میباشد (شکل (۱۱))، هدف انجام نگاشت اخیر هم اندازه نمودن کلاس ها و بررسی اثر این امر روی توانایی یادگیری شبکه می باشد. از نظر تئوری، هم اندازه نمودن کلاس ها میتواند یادگیری را بهبود بخشد زیرا باعث خطی تر شدن فضای کلاسه سازی می گردد و در یک شبکه عصبی که بر مبنای مدلسازی ریاضی شکل گرفته، این امر که مرزهای کلاس ها ضرایب صحیحی از مرز کلاس اول باشند، اثر مثبتی در یادگیری دارد.

این در حالی است که نتایج تجربی خلاف این امر را نشان میدهند: مجموعه سری اول (فضای غیر خطی) با ۲۵۲۰ تکرار و مجموعه سری دوم (فضای خطی شده با نگاشت) با ۲۷۵۰ تکرار به خطای $E_{trn} = 0.005$ میرسد و منحنیهای خطا در شکل های (۱۲) و (۱۳) نشان داده شده است.

همانگونه که در شکل ها ملاحظه می گردد، بر خلاف تصور قبلی، نگاشت انجام شده نه تنها اثر مثبتی در بهبود یادگیری نداشته است، بلکه باعث طولانی تر و مشکل تر شدن یادگیری نیز شده است. این تناقض می تواند بدین ترتیب توجیه و برطرف گردد:

از آنجا که یادگیری شبکه عصبی مصنوعی بر مبنای تجربیات متوالی و مکرر و یافتن خواص کلاس ها و ایجاد مرزهایی بین آنها انجام می شود، پردازش و نگاشت روی داده های خام منبعت از اصول ومبانی پدید آورنده کلاس ها، ممکن است ضرایب حساسیت نسبت به داده ها را بهم بزند. این احتمال بخصوص زمانی که این پردازش دارای یک تابع نگاشت غیر خطی است بسیار قوی می باشد.



شکل ۱۴: منحنی خطای یادگیری شبکه MLP برای داده های پردازش نشده.

حرکت به سمت کمینه (مینیمم)، و جلوگیری از اثرگذاری نابجای هر تغییر موقتی در مسیر حرکت می گردد.

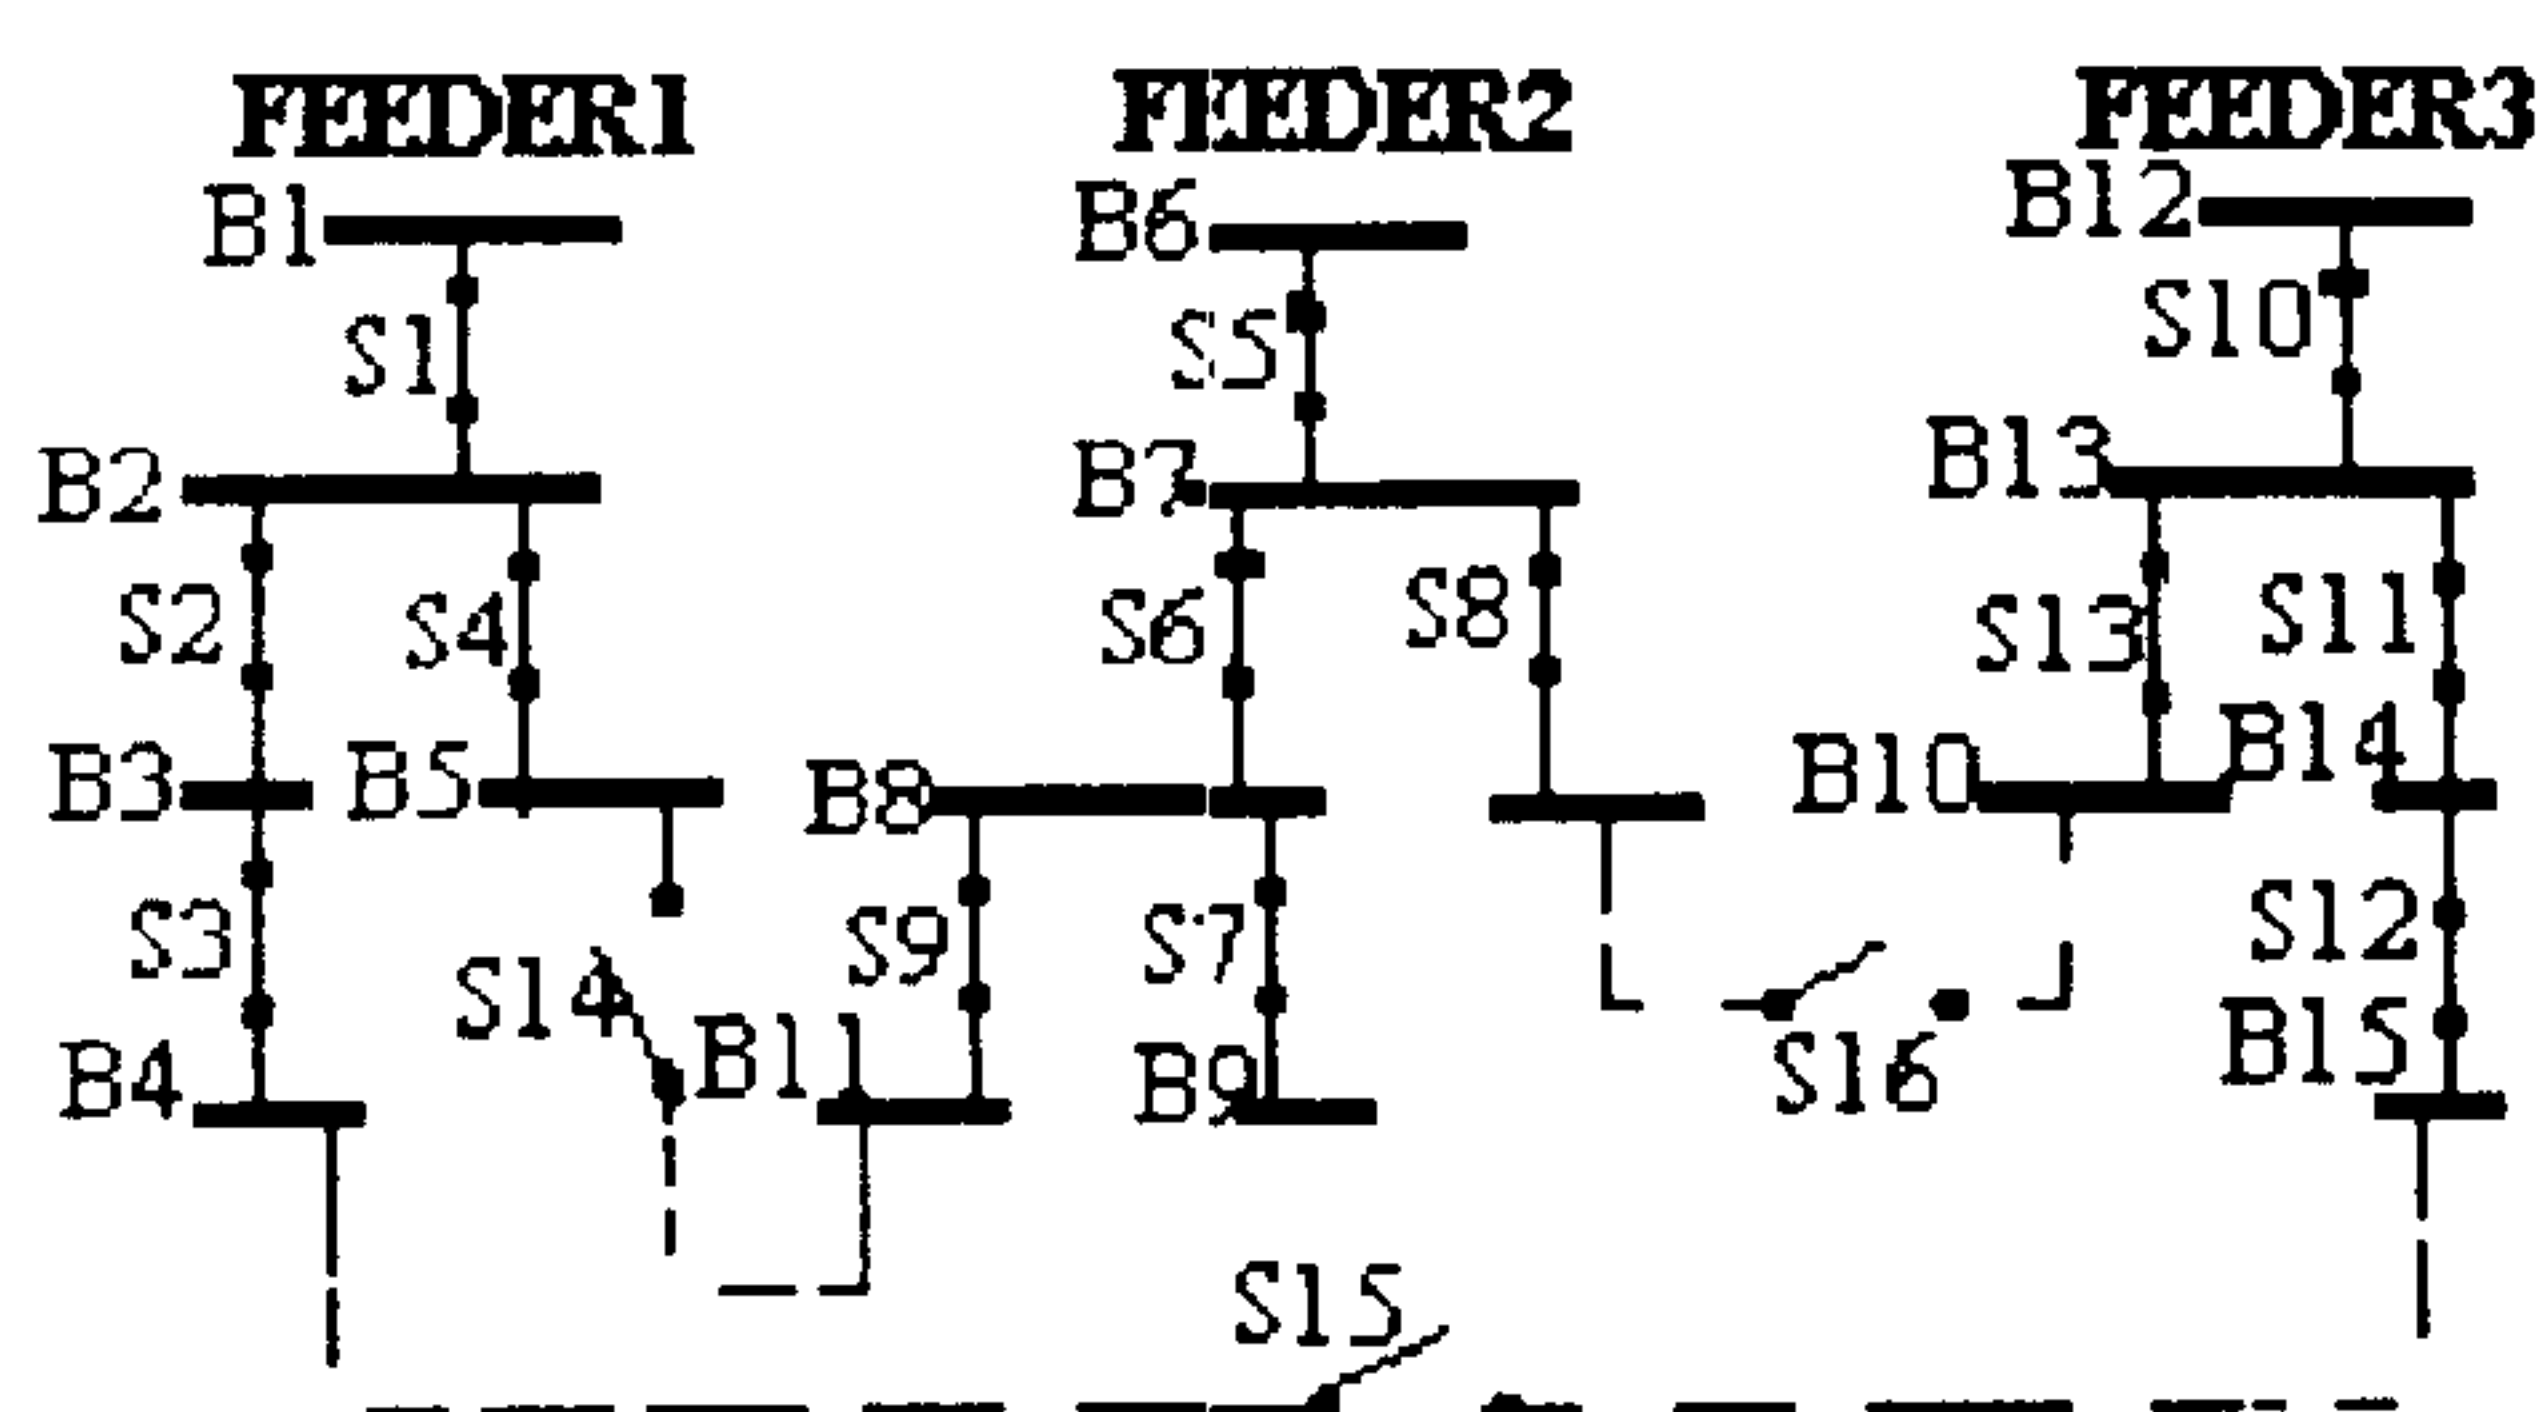
مطلب دیگر نرم [۱۰] مورد استفاده برای تابع خطا می باشد که انتخاب صحیح آن اثر قابل توجهی بر روند یادگیری شبکه می گذارد. به مطلب زیر که در مرجع [۱۷] بصورت ریاضی ثابت شده است توجه فرمایید:

اثر بزرگترین مولفه یک بردار بر نرم های درجات بالاتر، از اثرش بر نرم های درجات پایینتر بیشتر است.

یعنی هرچه درجه نرم بالاتر باشد، حساسیت نسبت به بزرگترین عنصر نرم نیز بیشتر می شود. این واقعیت بخوبی در حین آموزش شبکه مشاهده می گردد: در طول آموزش چندین بار اتفاق افتاد که علیرغم کاهش نرم کلی خطا، بزرگترین خطای نمونه ها افزایش می یافت، که این امر منجر به حصول تخمین های غیر قابل قبول در یکی از خروجیهای شبکه می گردید. در این حالت طبق مطلب فوق کفایت درجه نرم تابع خطا افزایش داده شود تا هر دو مقدار (نرم خطای کلی و بزرگترین خطای نمونه ها) بصورت همونا کاهش یابند. البته افزایش درجه نرم نیز با خطراتی از قبیل واگرایی سریع برنامه و مشکلات نقطه اعشاری و سرریز محدود می گردد. این مطلب اگر در بهینه سازی وزنه های شبکه عصبی مورد توجه قرار گیرد، می تواند اثر بسزایی در بهبود یادگیری آن داشته باشد.

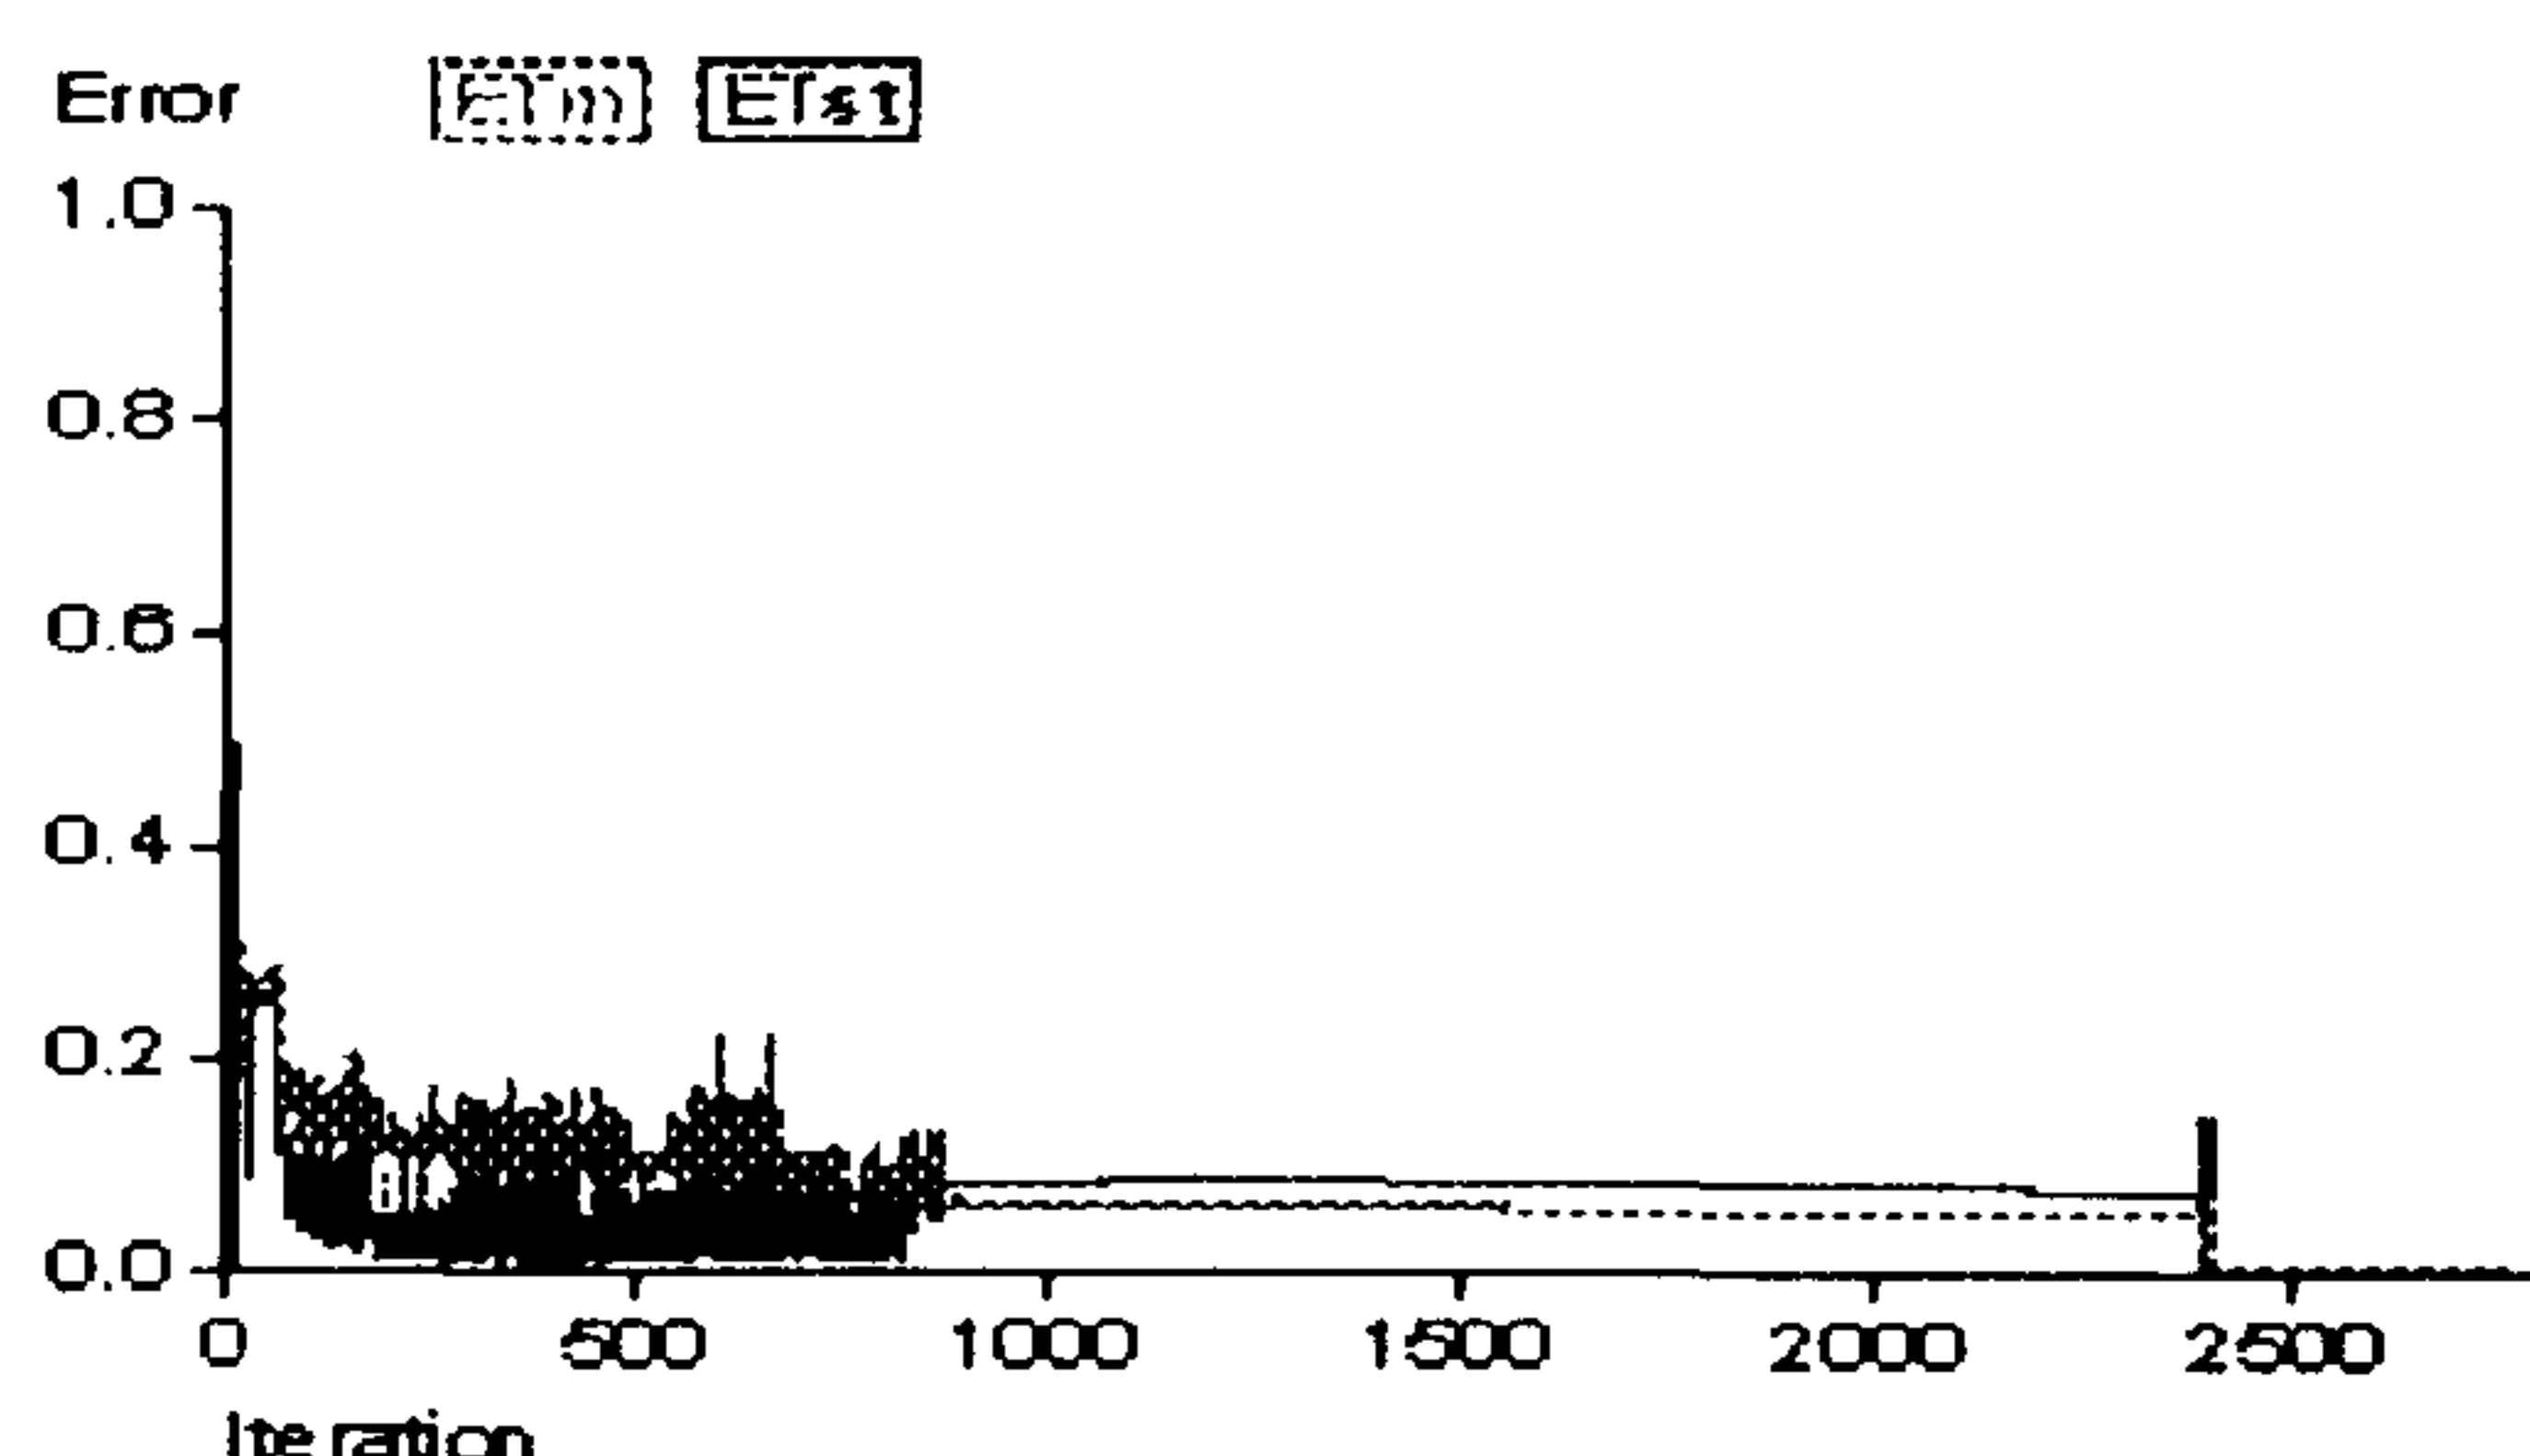
پیاده سازی عملی

برای نشان دادن کار آیی دو تخمین گر هوشمند طراحی شده و مقایسه آنان سیستم توزیع معروف سه فیدری شکل (۱۵) را که شامل ۱۶ کلید و ۱۳ قطعه خط می باشد، در نظر میگیریم [۴]. در این سیستم توزیع، هر قطعه خط یک ناحیه^۱ در نظر گرفته می شود و برای هر ناحیه یک متغیر حالت فرض می گردد، بنابراین بردار حالت این شبکه دارای ۱۳ عنصر می باشد. از این پس، این سیستم را "سیستم توزیع آزمون"^۲ خواهیم نامید.



شکل ۱۵: سیستم توزیع آزمون.

نموده است. جالب آنکه نرمالیزه نمودن [۰ و ۱] داده های حاصل از پیش-پردازش (نگاشت) نیز تعداد تکرارهای لازم برای یادگیری را به حدود ۳۲۰۰ برای خطای ۰/۰۰۵ افزایش میدهد (شکل (۱۴)).



شکل ۱۴: منحنی خطای یادگیری شبکه MLP برای داده های نگاشته و نرمالیزه.


داده های شکل (۶) یعنی فضای نگاشته شده دایره ای همانگونه که انتظار می رفت کیفیت یادگیری قابل قبولی نداشتند و علت این امر نیز همانند حالت قبل بهم خوردن ضرایب حساسیت نسبت به متغیرها می باشد. داده های توزیع شده گاوسی (اشکال (۲)، (۵) و (۷)) نیز روی شبکه MLP آزموده شده اند اما یادگیری آنان بهیچوجه قابل مقایسه با یادگیری داده های یکنواخت (وبا تکیه بر مرزهای کلاس ها) نبود. این امر نشان می دهد که شبکه های MLP بر خلاف شبکه های RBF برای یادگیری خوب نیازی به داده های متمرکز در مرکز کلاس ها ندارند و بر عکس، لازم است که داده های آموزش داده شوند به آنان توزیعی یکنواخت (والبتنه ترجیحاً با تمرکز در مرزهای کلاس ها) داشته باشند. خلاصه کلام آنکه " شبکه های عصبی MLP، شبکه های مرزگرا می باشند و برای آموزش آنان باید روی مرزهای کلاس ها تکیه نمود."

در مورد طول گام (ضریب یادگیری) α و مومنتم β باید اشاره گردد که از آنجا که انتخاب و تغییرات این مقادیر قاعده مشخصی نداشته و کمیاتی فراکتال میباشند، در برنامه کامپیوتری آموزش شبکه عصبی امکان تغییر آنها بصورت تطبیقی وجود داشته و ایندو بترتیب مقادیر 0.9 تا 1.1 و 0.7 تا 0.95 را اختیار مینموده اند. در اینمورد ذکر این نکته لازم است که در صورت کم بودن مومنتم نمیتوان مقدار طول گام را تا این حد بالا برد و عدم توجه به این مسأله می تواند باعث ناپایدار (واگرا) شدن روند بهینه سازی ضرایب گردد. این در حالی است که بالا بردن متناسب مومنتم موجب لخت تر (اینرسی) نمودن روند

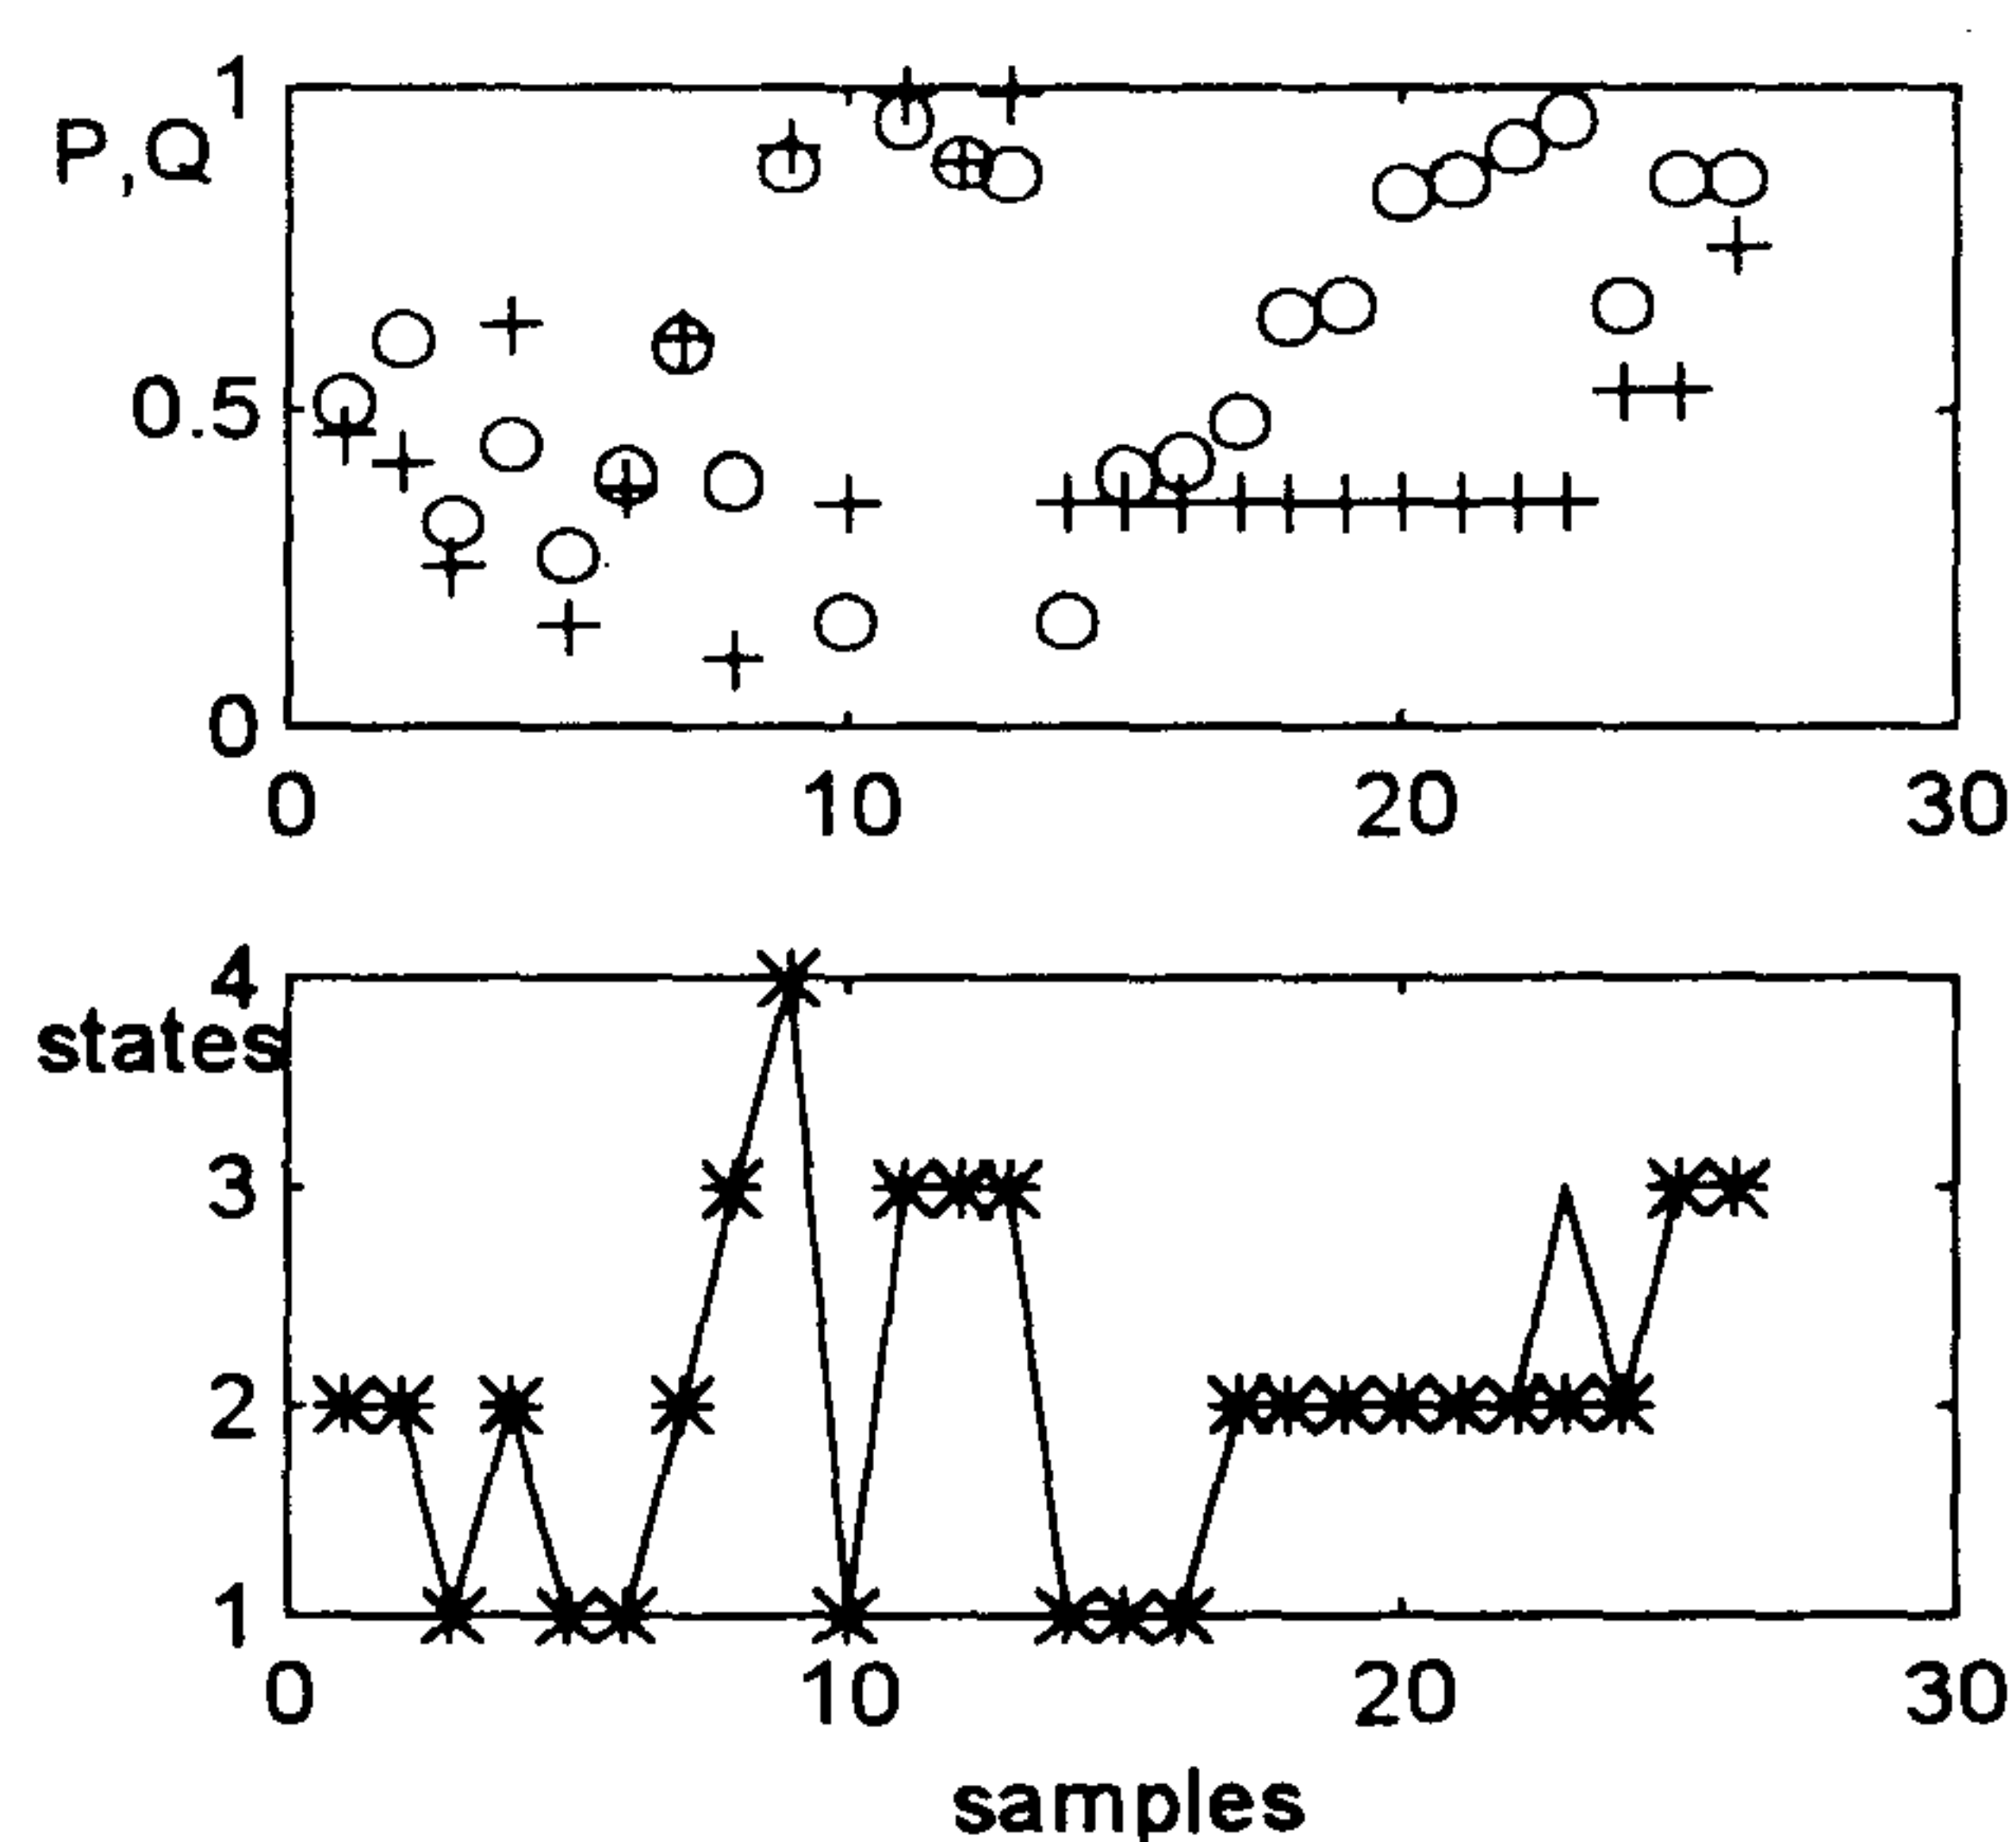
1 - Zone

۲ - این سیستم در بیشتر مطالعات سیستم توزیع IEEE (انستیتو مهندسیین برق و الکترونیک) مورد استفاده قرار گرفته است و به شبکه سه فیدری مشهور است.

از داده های اندازه گیری شده در سیستم توزیع آزمون شکل (۱۵) مورد استفاده قرار می گیرد. در اینجا نیز بدلیل دقت آموزش و کلاسه سازی صد در صد یادگیری مجموعه آموزشی شبکه، داده های آزمون، واقعی و جدید هستند و قبلاً به شبکه آموخته نشده اند و بنابراین قدرت تعمیم شبکه سنجیده می شود. سری اول داده ها (۱۳ نمونه اول) مربوط به عملکرد شبکه در حالت عادی و نمونه های سری دوم (نمونه های ۱۴ تا ۲۶) مربوط به یک حالت خطاست که در شبکه رخ داده و ورودیها و خروجیهای تخمین گر برترتیب در بالا و پایین شکل (۱۷) ملاحظه می گردند.



شکل ۱۶: ورودی (بالا) و خروجی (پایین) تخمین گر RBF برای سنجش قدرت تعمیم آن.



شکل ۱۷: ورودی (بالا) و خروجی (پایین) تخمین گر MLP برای سنجش قدرت تعمیم آن.

همانگونه که در شکل (۱۷) مشاهده می گردد، حالت داده های سری اول با دقت صد در صد بدست آمده است، لذا این تخمین گر در مورد داده های جدید نیز بخوبی

آزمون تخمین گر RBF

همانگونه که نشان داده شد برای آموزش شبکه های RBF، داده های گاوسی (خوشه ای یا متمرکز) از داده های با توزیع یکنواخت بسیار مناسبترند، لذا شبکه RBF آموزش یافته با داده های گاوسی بعنوان شبکه نمونه مورد آزمون قرار می گیرد:

برای این منظور، داده های دو سری اندازه گیری توان اکتیو و راکتیو را در سیستم توزیع آزمون (۲۶ نمونه) در نظر می گیریم که در نمودار بالایی شکل (۱۶) ملاحظه میگردند، هیچیک از این داده ها قبلاً به شبکه عصبی مستقیماً آموخته نشده اند و جزء مجموعه آموزشی شبکه نبوده اند. یادآوری این نکته ضروری است که در مرحله یادگیری، تمام داده های مجموعه آموزشی شبکه با توانایی کلاسه سازی صد در صد آموخته شده اند و به همین دلیل در اینجا داده های تکراری آزموده نمی شوند زیرا شبکه طراحی شده آزمون موفق روی این داده ها داشته است.

سری اول (۱۳ نمونه اول) مربوط به مقادیر اندازه گیری شده در حالت عادی عملکرد سیستم میباشد. همانگونه که در بخش پایین شکل (۱۶) مشاهده میگردد، این داده ها سه مورد خطا داشته اند که خطای قابل قبولی نیست. سری دوم مربوط به حالتی است که خطایی در سیستم توزیع آزمون رخ داده است، مثلاً قطع یک خط و بالارفتن ناخواسته ظرفیت خازنی آن و تغییر غیر طبیعی ضریب قدرت سیستم (کسینوس فی). داده های این سری خارج از محدوده کلاس ها می باشند (برونبایی) و تخمین گر باید بتواند بر مبنای تخمین حداکثر شباهت و یا حداقل فاصله از مرکز کلاس (مثلاً فاصله همینگ)، شبیه ترین کلاس (حالت) را به داده های وارد شده به آن تخمین بزند. پاسخ این حالت نیز در بخش پایین شکل (۱۶) ملاحظه میگردد، در این مورد دو خطا وجود داشته که هر دو مربوط به وضعیت اضطراری حاد و غیر محتمل میباشد. در بخش بعد ملاحظه خواهد شد که تخمین گر MLP توانایی قابل ملاحظه ای در این زمینه دارد.

آزمون تخمین گر MLP

در اینجا شبکه عصبی آموزش یافته با داده های توزیع شده یکنواخت پردازش نشده بعنوان بهترین شبکه طراحی شده، آزمایش می شود: برای آزمودن این شبکه دو سری

• شبکه عصبی MLP طراحی و انتخاب شده در این مقاله دارای ابعادی بسیار کوچکتر از شبکه های معرفی شده در سایر مقالات می باشد [۸،۱۲].

• خطی نمودن فضای کلاسه سازی بوسیله پیش پردازش غیر خطی، لزوماً باعث بهبود یادگیری شبکه عصبی MLP نمی گردد و بدلیل بر هم زدن ضرایب حساسیت، می تواند باعث بدتر شدن یادگیری شود. این امر بشکل تجربی و با اثبات ریاضی در این مقاله نشان داده شده است.

• برای کاربرد کلاسه سازی مورد نظر در این مقاله، قدرت یادگیری، یادآوری و تعمیم (درونیایی و برونیایی) شبکه MLP بسیار بیشتر از شبکه RBF می باشد، این در حالیست که در برخی از کاربردها عکس این مطلب گزارش شده است [۶].

• افزایش درجه تابع خطای یادگیری شبکه (نرم l-p) از طرفی منجر به کنترل افزایش ناخواسته خطای یادگیری یکی از خروجیهای شبکه (افزایش حساسیت نسبت به بزرگترین خطا) [۱۷] و از طرف دیگر امکان ناپایدار شدن برنامه آموزش می گردد، در انتخاب این نرم باید بین این دو عامل مصالحه گردد.

• علیرغم شکل دایره ای مقطع تابع گاوسی دو بعدی نورون های شبکه RBF، تبدیل کلاسه های مربعی به کلاسه های بفرم دواپر متداخل بکمک نگاشت همدریس در صفحه مختلط، اثری در بهبود یادگیری این شبکه عصبی ندارد. شاید بتوان علت این امر را بهم خوردن ضرایب حساسیت و فرم اصلی و قانونمند اولیه فضای کلاسه سازی مربعی دانست.

• اثر مثبت اعمال نویز تصادفی به ورودیهای آموزشی، در دو حالت زیر تجربه شده است:

۱. روند یادگیری و محاسبه ماتریسهای ضرایب و خطای یادگیری، دچار مشکلاتی نظیر تقسیم بر صفر و بدحالی شده است.

۲. روند یادگیری بسیار کند شده و یا در یک مینیمم موضعی گیر کرده است.

• شبکه عصبی RBF از نظر یادگیری، یادآوری و تعمیم یک شبکه مرکزگرا است.

• شبکه عصبی MLP از نظر یادگیری، یادآوری و تعمیم یک شبکه مرکزگرا است.

عمل می نماید. اما در مورد داده های سری دوم که هشت عدد از نواحی دچار مشکل شده اند و ضریب قدرت سیستم آزمون در این نواحی از حد مجاز عبور نموده است، یعنی مقادیر داده شده به شبکه خارج از محدوده کلاس ها میباشد (برونیایی) و تخمین گر بر مبنای تخمین حداکثر شباهت باید کلاس نزدیک تر را تخمین بزند. ملاحظه می گردد که فقط در یک مورد حالت تخمین اشتباه زده شده است که آنهم موردی است که رخداد آن بسیار غیر محتمل است، یعنی حالتی که ضریب قدرت (کسینوس فی) آن ناحیه از سیستم ۶۰٪ تغییر نماید که خبرگان سیستم های توزیع تصدیق می کنند احتمال رخ دادن چنین حالتی بسیار کم است. ملاحظه میگردد که شبکه عصبی MLP تخمین گری است که بخوبی از عهده تخمین حداکثر شباهت (حداقل فاصله) برای داده های خارج از کلاس می آید، این ویژگی نتیجه قدرت تعمیم (هوشمند بودن) شبکه عصبی MLP می باشد.

این توانایی مهم تخمین گر MLP که در کاربردهای خاص بسیار قابل توجه میباشد، (تخمین حداکثر شباهت یا حداقل فاصله در خارج از منطقه کلاس ها بمنظور تخمین حالت سیستم تحت خطا) در هیچیک از مقالات با زمینه مشابه بروشنی مشاهده نگردیده است [8,12]. بنابراین ملاحظه میگردد که شبکه MLP برای کاربرد مورد نظر در این مقاله بسیار قدرتمندتر از شبکه RBF چه در زمینه یادگیری و چه در زمینه تعمیم - عمل مینماید.

نتیجه گیری

• تخمین گر هوشمند MLP ارائه شده در این مقاله، بخوبی از عهده تخمین صحیح حالت سیستم توزیع آزمون IEEE برمی آید و ابزار بسیار مناسبی برای یک سیستم مدیریت و کنترل توزیع (DMS یا DAC) می باشد. این مطلب طی مثالی عملی با مقایسه نتایج سیستم طراحی شده و نتایج واقعی (که یکسان هستند) نشان داده شده است.

• شبکه عصبی (تخمین گر) MLP طراحی و انتخاب شده در این مقاله، توانایی تخمین حداکثر شباهت و حداقل فاصله برای داده های خارج از کلاس ها (برونیایی) را دارد و بنابر این قادر به عملکرد مناسب تحت شرایط بحران و خطا نیز می باشد. این ویژگی نتیجه هوشمند بودن سیستم میباشد و گزارش این توانایی در مقالات مشابه مشاهده نشده است [۸،۱۲].

مراجع

- 1 - Allemong, J. J., Radu, L. and Sasson, A. M. (1982). "A fast and reliable state estimation algorithm for AEP's New control center." *IEEE Transactions on PAS*, Vol. PAS-101, PP. 933-944.
 - 2 - Bose, N.K. and Liang, P. (1996). *Neural network fundamentals with graphs, algorithms and applications*. McGraw-Hill.
 - 3 - Churchill, R. V., Brown, J. W. and Verhey, R. F. (1974). *Complex variables and applications*. 3rd Edition, McGraw-Hill.
 - 4 - Civanlar, S., Grainger, J. J., Yin, H. and Lee, S. S. H. (1988). "Distribution feeder reconfiguration for loss reduction." *IEEE Transactions on PWRD*, Vol. 3, No. 3.
 - 5 - Dopazo, J. F., Kiltin, O. A., Stagg, G. W. and VanSlyck, L. S. (1970). "State calculation of power systems from line flow measurements." *IEEE Transactions on PAS*, Vol. PAS-89, PP.1698-1708.
 - 6 - Hush, D. R. and Horn, B. G. (1993). "Progress in supervised neural networks." *IEEE Signal Processing Magazine*.
 - 7 - Kalman, R. E. (1961). "A new approach to linear filtering and prediction problems." *Transactions of ASME (J. Basic Engineering)*, Vol. 28D, No. 1, PP. 95-108.
 - 8 - Kim, H., Ko, H. and Jung, K. H. (1993). "Artificial neural-network based feeder reconfiguration for loss reduction in distribution systems." *IEEE Transactions on PWRD*, Vol. 8, No. 3.
 - 9 - Melsa, P. J. W. (1986). "Networks: A conceptual overview." *TRC-89-08*.
 - 10 - Reddy, J. N. (1970). *Applied functional analysis and variational methods engineering*. McGraw-Hill.
 - 11 - Ogata, Katsuhiko. (1970). *Modern control engineering*. Prentice-Hall.
 - 12 - Santoso, N. I. and Tan, O. T. (1993). "Neural-net based real-time control of capacitors installed on distribution systems." *IEEE Transactions on PWRD*, Vol. 8, No. 4.
 - 13 - Schwepe, F. C. and Handschin, E. (1974). "Static state estimation in power systems." *IEEE Proceedings*, Vol. 62.
 - 14 - Simoes-Costa, A. and Quintana, V. H. (1981). "A robust numerical technique for power system state estimation." *IEEE Transactions on PAS*, Vol. PAS-100, PP.691-698.
 - 15 - Stott, B. (1972). "Fast decoupled load flow." *IEEE Transactions on PAS*, Vol. PAS-91, PP.1955-1959.
 - 16 - Vemori, V. (1988). "Artificial neural networks: theoretical concepts." *IEEE Computer Society Press*.
- ۱۷ - فریدونیان، ع. ر. "بهینه سازی و اتوماسیون هوشمند سیستم های توزیع به وسیله شبکه های عصبی." پایان نامه کارشناسی ارشد، دانشگاه تهران، دانشکده فنی، (۱۳۷۶).
- ۱۸ - فریدونیان، ع. ر.، لسانی، ح. و لوکس، ک. "بهینه سازی و اتوماسیون سیستم های توزیع بمنظور کاهش تلفات و ایجاد تعادل بار بکمک شبکه های عصبی." مجموعه مقالات هفتمین کنفرانس مهندسی برق ایران، مرکز تحقیقات مخابرات ایران، اردیبهشت (۱۳۷۸) صص: ۴۸۸ تا ۴۹۹.

واژه نامه:

1 - Radial Basis Function	شبکه عصبی با تقارن شعاعی
2 - Multi Layer Perceptron	شبکه عصبی پرسپترون چند لایه
3 - Classification	کلاسه سازی
4 - Scaling	مقیاس نمودن
5 - Pre - Processing	پیش - پردازش
6 - Conformal Mapping	نگاشت همدیس
7 - Generalization	قدرت تعمیم
8 - Distribution Management System	سیستم های مدیریت توزیع
9 - Distribution Automation Control	کنترل و اتوماسیون توزیع
10 - Center Oriented	مرکز گرا
11 - Bound Oriented	مرز گرا
12 - Deterministic	حالت موجبی
13 - Stochastic	ویژگیهای تصادفی
14 - Cross Validation	روش اعتبار متقابل
15 - Overtraining or Overfitting	آموزش بیش از حد