

پیشنهاد توابع فعال ساز بازه‌ای در شبکه عصبی بر پایه توابع شعاعی برای پیش‌بینی سیستم‌های غیر خطی پویا

الله‌یار ظهوری زنگنه^۱، محمد تشنلوب^۲، مجتبی احمدیه خانه‌سر^۳

^۱ دانشجوی دکترا مهندسی کامپیوتر هوش مصنوعی، گروه کامپیوتر، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران،

z.zangeneh@gmail.com

^۲ استاد، قطب علمی کنترل صنعتی، دانشکده مهندسی برق، گروه کنترل، دانشگاه صنعتی خواجه نصیرالدین طوسی، teshnehlab@etd.kntu.ac.ir

^۳ استاد بار، دانشکده برق و کامپیوتر، گروه مهندسی قدرت و کنترل، دانشگاه سمنان، ahmadieh@semnan.ac.ir

تاریخ دریافت مقاله ۱۳۹۶/۷/۲۳، تاریخ پذیرش مقاله ۱۳۹۶/۱۰/۴

چکیده: «شبکه عصبی بر پایه توابع شعاعی»^۱ یک تغیریگر غیرخطی می‌باشد. در این مقاله «تابع فعال ساز گرانولی»^۲ برای بهبود یادگیری این شبکه در نوبتی پیشنهاد می‌گردد که بک نایاب گاووسی با «انحراف استاندارد بازه‌ای و میانگین ثابت» است و به آن «تابع فعال ساز بازه‌ای» نیز گفته می‌شود. در لایه میانی این شبکه، سه پارامتر وابسته به توابع فعال ساز گرانولی آموزش می‌یابند که «مرکز توابع فعال ساز گرانولی» که مرکز دسته نامیده می‌شود، کران پائین انحراف استاندارد و کران بالای انحراف استاندارد این توابع می‌باشد. در لایه خروجی دو پارامتر دیگر یعنی «مرکز وزن‌های بازه‌ای» و «بازه این وزن‌ها» آموزش می‌یابند. برای آموزش این پارامترها از روش «الگوریتم خوشبتدی K-Means» استفاده شده است. در این روش، آموزش شبکه در راستای «گرانوله سازی» پائین به بالا^۳ می‌باشد که در آن بردارهای ورودی به شکل گرانولهای بزرگ در لایه میانی خوشبتدی می‌گردند. از روش «گرادیان نزولی» نیز برای آموزش پارامترهای شبکه استفاده شده و نتایج با روش جدید مقایسه گردیده است. عملکرد این شبکه با شناسایی «یک سیستم غیرخطی پویای U شکل با پنج ورودی^۴» و پیش‌بینی «سری زمانی آشوب مکی گلاس^۵ در شرایط نوبتی و بدون نوبت سنجیده می‌شود. از نتایج معلوم می‌گردد که استفاده از تابع فعال ساز گرانولی در ساختار شبکه عصبی RBF^۶ باعث کاهش حسابت به تغیرات ورودی شده و عملکرد آن در شرایط نوبتی بهبود می‌یابد.

کلمات کلیدی: شبکه عصبی بر پایه توابع شعاعی گرانولی، تابع فعال ساز گرانولی، داده‌های نوبتی، انحراف استاندارد بازه‌ای، سیستم‌های غیرخطی پویا و توابع آشوب.

Proposing Interval Activation Functions in Radial Basis Function Neural Network to Predict Nonlinear Dynamic Systems

Allahyar Zohoori Zangeneh, Mohammad Teshnehlab, Mojtaba Ahmadih Khanesar

Abstract: A Radial Basis Function Neural Network (RBFNN) is a general approximator. In this paper a granular activation function is proposed to improve its learning under the noisy conditions. The granular activation function is also named the interval activation function and it is typically the Gaussian function which benefits from having a fixed mean and an uncertain standard deviation. The hidden layer of the proposed network has a total of three parameters to train that it consists the means, the lower bounds of the standard deviations and the higher bounds of the standard deviations of the Gaussian functions. The output layer parameters for training are the means of the interval weights and the intervals of the weights. “K-Means clustering algorithm” method is used to train

^۱ Radial Basis Function Neural Network (RBFNN)

^۲ Granular activation functions

^۳ Bottom-up granulation

^۴ Nonlinear dynamic system with multiple time delays

^۵ Mackey glass chaotic time series

^۶ Granular Radial Basis Function Neural Network (GRBFNN)

these parameters. The purpose of the above learning method is regarded as one of the granular method presenting the bottom-up granulation which causes the input vectors clustered in the larger granules in the hidden layer. Gradient descend method is also used to train these parameters to compare with this novel method. The structure is tested with or without noisy data to identify a nonlinear dynamic system with multiple time delays and to predict a chaotic model, Mackey-Glass. It has been shown that the sensibility related to input alterations reduces because of using the granular activation function in RBF Neural Network structure and the response of Granular RBF Neural Network with noisy data is better than RBF Neural Network.

Keywords: Granular Radial Basis Function Neural Network (GRBFNN), Granular activation function, Noisy data, Interval standard deviation, Nonlinear dynamic systems and Chaotic Models.

پیش‌بینی و کنترل سیستم‌ها استفاده شده و قابلیت خود را به خوبی نشان داده است. به سبب قابلیت‌های خوب این شبکه‌ها، می‌توان از آن به عنوان یک مدل کننده خطی سازی محلی و یک روش خطی سازی متغیر در تخمین حالت و کنترل نیز نام برد^[۲].

روش آموزش پارامترها در شبکه عصبی RBF گرانولی یک مسئله با اهمیت است. یکی از این روش‌ها بر مبنای «گرادیان نزولی»^۱ بنا شده است، که محاسبه مشتق در بعضی مراحل آن در فاتحون زنجیره‌ای^۲ بسیار دشوار است. از طرفی به کار بردن آن ممکن است ما را در می‌تیسم محلی^۳ گرفتار سازد^[۳۶، ۳۵]. پیجدگی «الگوریتم گرادیان نزولی» برای آموزش پارامترها در شبکه عصبی RBF و شبکه عصبی RBF گرانولی فارغ از تعداد ورودی‌ها از درجه^۴ ۴ یعنی $O(m \times n \times T \times Epoch)$ می‌باشد؛ که تعداد نمونه‌های m تعداد نمونه‌های لایه میانی، n ابعاد ورودی‌ها، T تعداد دفعات تکرار الگوریتم است^[۳۵]. در این ورودی و $Epoch$ تعداد دفعات تکرار الگوریتم است^[۳۵]. در این پژوهش سعی شده است یک روش دیگر که بتواند پارامترها را سریع تر و آسان‌تر از «گرادیان نزولی» آموزش دهد معرفی گردد. زیرا در روش «گرادیان نزولی» همگرایی پارامترها به شدت وابسته به شدت وابسته به نرخ آموزش^۵ مناسب است که اغلب بافت آن بسیار دشوار می‌باشد^[۳۶].

در روش پیشنهادی این مقاله که «الگوریتم خوشبندی K-Means»^۶ نامیده می‌شود همگرایی پارامترها سریع تر و در تعداد دفعات تکرار(مرحله)^۷ کمتری^[۲۲، ۴۴] صورت می‌گیرد. پیجدگی «الگوریتم خوشبندی K-Means» برای آموزش پارامترها در شبکه عصبی RBF گرانولی بدون ترجمه به تعداد ورودی‌ها از درجه^۳ ۳ یعنی $O(m \times T \times Epoch)$ می‌باشد؛ که تعداد خروجی‌های^۸ همان تعداد نمونه‌های نمونه‌های لایه میانی^۹، T تعداد دفعات تکرار الگوریتم است^[۳۷]. آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means»

۱- مقدمه

یک تابع شاعی^{۱۰} تابعی است که مقدار آن فقط به فاصله از یک نقطه که مرکز دسته می‌باشد وابسته است. این تابع در تخمین^{۱۱} [۲۲]، پیش‌بینی سری‌های زمانی^{۱۲} [۴۳، ۱] و کنترل^{۱۳} [۲۲] مورد استفاده قرار می‌گیرند. در یک شبکه عصبی، از این تابع می‌توان به عنوان تابع فعال‌سازی نمون استفاده کرد. یک شبکه عصبی بر پایه تابع شاعی در حالت کلی شامل سه لایه می‌باشد، لایه ورودی، لایه میانی با همان لایه پنهان^{۱۴} و لایه خروجی^{۱۵} [۱، ۲۶].

در این مقاله یک شبکه عصبی RBF گرانولی، برای برداشتن سیستم‌های همراه با نویز معرفی می‌گردد. تابع دارای «میانگین بازه‌ای و انحراف استاندارد ثابت»^{۱۶} و یا «انحراف استاندارد بازه‌ای و میانگین ثابت»^{۱۷}، دو نوع تابع فعال ساز گرانولی می‌باشد^[۲۳، ۷، ۶]. یک شبکه عصبی RBF گرانولی، تابع فعال ساز گاوسی گرانولی با «انحراف استاندارد بازه‌ای و میانگین ثابت»، را در یک سیستم عصبی وارد می‌نماید تا مقاومت در برابر نویز آن را افزایش دهد^[۷، ۶، ۱۱، ۱۸، ۱۰].

یک سیستم عصبی گرانولی روشی مناسب‌تر نسبت به دیگر شبکه‌های عصبی در بررسی عدم قطعیت‌ها می‌باشد^[۵]. زیرا در صورت وجود نویز در مقادیر ورودی، پایداری سیستم را در مقابل آن افزایش می‌دهد^[۶، ۷، ۱۰].

یک شبکه عصبی RBF گرانولی، می‌تواند به عنوان کلاسی از شبکه‌های تطبیق‌پذیر محسوب گردد. شبکه‌های عصبی تطبیق‌پذیر، توسعه بافته شبکه‌های پیش رو هستند که تابع فعال ساز نمونه‌های آن می‌تواند به هر فرمی باشد یعنی لزومی ندارد به صورت سیگموید، سینوسی یا گاوسی باشد^[۲]. این کلاس از شبکه‌های تطبیق‌پذیر در کاربردهای شناسایی،

^۱ Radial basis

^۲ Estimation

^۳ Time series prediction

^۴ Hidden Layer

^۵ Granular activation function having an uncertain mean and fixed standard deviation σ

^۶ Granular activation function having an uncertain standard deviation σ and fixed mean

^۷ Gradient descend

^۸ Chain rule

^۹ Local minimum

^{۱۰} Learning rate

^{۱۱} K-Means clustering algorithm

^{۱۲} Epoch

بویا و پیش‌بینی تابع آشوب دارد؟ این تفاوت در خطای شناسایی و پیش‌بینی زمان اجرای برنامه چگونه خواهد بود؟

- کارایی شبکه عصبی RBF گرانولی در مدیریت عدم قطعیت ناشی از شرایط نویزی؛ نسبت به دیگر شبکه‌های عصبی و عصبی فازی چگونه است؟ آبا به کار بردن شبکه عصبی RBF گرانولی نسبت به دیگر سیستم‌های هوشمند دارای مزیت است؟

۲- مورد کارهای انجام شده در زمینه نویز و کاهش اثر آن^۵

۱-۲ تعریف نویز

در یک تعریف کلی، به هر نوسان و تغییر ناخواسته که بر روی سیگنال‌های مورد اندازه‌گیری ظاهر شود، نویز گفته می‌شود. هر کیمی می‌تواند نویزی گردد [۱۶، ۱۴].

- در مدارهای الکترونیکی بیشتر با نویز ولتاژ و جریان سر و کار داریم؛ این نویز ناشی از تغیرات دمایی محیط انتقال انرژی و تاثیر آن بر روی حرکت الکترون‌ها است.

- در حوزه امواج رادیویی و مایکروویو^۶ با نویزهای الکترومغناطیسی و گاهی نیز با نویزی که ناشی از گرمایش^۷ و یون-های کم انرژی باشد روبرو هستیم.

در هر آزمایش دقیق و با کیفیت بالایی که انجام می‌شود، باید بتوان نویز محیط را پیش‌بینی و تاثیر آن را کم کرد. احتیت تحلیل نویز هنگامی کاملاً نهایان می‌شود که متوجه می‌شویم کیفیت سیگنال اندازه‌گیری شده تنها به مقدار انرژی سیگنال استگنگی ندارد بلکه به وسیله «نسبت سیگنال به نویز» تعیین می‌شود. نتیجه تحقیقات نشان می‌دهد که بهترین روش برای بهبود «نسبت سیگنال به نویز»، کاهش نویز است نه افزایش قدرت سیگنال [۱۶، ۱۱].

۲-۲ فرآیند تولید نویز

نویز طبق تعریف، غیر قابل کنترل است و مقدار دقیق آن در آزمایش‌های گوناگون با هم متفاوت است. پس در واقع فرآیند تولید نویز از نوع فرآیندهای تصادفی است و معمولاً تابع توزیع احتمال^۸ [۳۹] متفق تصادفی نویز را بر اساس قضیه حد مرکزی^۹ به شکل گاوی با

انعطاف‌پذیری سیستم را نسبت به آموزش با روش «گرادیان نزولی»، افزایش می‌دهد [۲۳، ۲۷].

از طرفی «الگوریتم خوشبندی K-Means» در شناسایی و پیش‌بینی تابع آشوب با محدودیت‌هایی روبرو است؛ زیرا دو بردار ورودی که فاصله اقلیدسی^{۱۰} کوچکی دارند و ممکن است در لایه پنهان در یک خوشه^{۱۱} قرار گیرند، می‌توانند در این گونه توابع خروجی‌های دور از هم داشته باشند. مگر این که افق پیش‌بینی را در این تابع به قدری کوچک در نظر بگیریم تا دو بردار ورودی که فاصله اقلیدسی کوچکی دارند، خروجی‌های نزدیک به هم تولید کنند [۲۸، ۲۷] به همین دلیل، بکار بردن «الگوریتم خوشبندی K-Means» سبب می‌گردد که وزنهای لایه خروجی بار بیشتری را در شناسایی و پیش‌بینی تابع آشوب تحمل نمایند [۲۷]. ولی در مورد شناسایی سیستم‌های غیر خطی بویا که آشوبی نیستند، «الگوریتم خوشبندی K-Means» در تعداد تکرار کمتر عملکرد بهتری دارد.

عملکرد شبکه عصبی RBF گرانولی، بوسیله شناسایی «بک سیستم غیر خطی بویا با پنج ورودی» [۶] و پیش‌بینی «سری زمانی آشوب مکی گلاس» [۲۰]، مورد آزمایش قرار می‌گیرد [۲۷]. نویز به کار رفته دارای «نسبت سیگنال به نویز» برابر صفر، پنج و ده خواهد بود که با شرایط بدون نویز مقایسه می‌گردد [۱۱].

از آنجا که در رابطه با آموزش پارامترهای لایه میانی شبکه عصبی RBF گرانولی، به کمک «الگوریتم خوشبندی K-Means» و «گرادیان نزولی» در شرایط نویزی و بدون نویز و مقایسه آن‌ها با یکدیگر و با دیگر شبکه‌های عصبی و عصبی فازی، بیووهشی انجام شده است، این مقاله به منظور پاسخ به پرسش‌های زیر شکل گرفته است:

- شبکه عصبی RBF گرانولی، با آموزش پارامترهای لایه میانی بوسیله دو روش «الگوریتم خوشبندی K-Means»، با «گرادیان نزولی»، و پارامترهای لایه خروجی بوسیله روش «گرادیان نزولی»، نسبت به شبکه عصبی RBF با آموزش همه پارامترها بوسیله روش «گرادیان نزولی»، در کدام بک از شرایط نویزی و بدون نویز بهتر عمل می‌کند؟

- ایجاد یک ساختار بازه‌ای در دو پارامتر (الف) انحراف استاندارد و تابع فعال‌ساز گرانولی که بک پارامتر غیرخطی لایه میانی است (ب) وزنهای لایه خروجی که بک پارامتر خطی لایه خروجی است، چه تاثیری در افزایش کارایی سیستم در شرایط نویزی خواهد داشت؟

- در شبکه عصبی RBF گرانولی، آموزش پارامترهای غیرخطی لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» در مقایسه با «الگوریتم گرادیان نزولی»، چه تفاوتی در شناسایی سیستم‌های غیر خطی

^۵Noise Reduction

^۶Microwave

^۷Radiation

^۸Probability Distribution Function (PDF)

^۹نظریه حد مرکزی بیان می‌کند که اگر تعداد نمونه‌های یک متغیر تصادفی به سمت بینهایت می‌کند، تابع توزیع احتمال آن متغیر تصادفی به سوی توزیع نرمال میل می‌کند.

^{۱۰}Euclidean distance

^{۱۱}Cluster

^{۱۲}Mackey glass chaotic time series

^{۱۳}Signal to Noise Ratio(SNR)

به ازای هر مقدار ϵ باید ثابت باشد. برخی از صومی ترین نویزهای موجود، عبارتند از:

• **نویز سفید^۱**: به بک دنباله نویزی مانند $(n_r^{(t)})_{r \in N}$ نویز سفید گفته می‌شود اگر متغیر تصادفی $n_r^{(t)}$ در این دنباله دارای میانگین صفر بوده و داشته باشیم:

$$E((n_r^{(t)})^2) = Var(n_r^{(t)}) = \sigma_n^2 = \\ a \text{ constant value} \quad (4)$$

تابع چگالی توان^۲ و با طیف توان^۳ نویز سفید به فرکانس آن بستگی ندارد و دارای دامنه ثابتی برابر σ_n^2 است که به آن توان نویز گفته می‌شود. البته این بک تعریف ایده‌آل است زیرا اگر از یک عدد ثابت نسبت به فرکانس انگرال بگیریم، واریانس نویز (با همان توان نویز) بی‌نهایت به دست می‌آید. نویز سفید به دو صورت ظاهر می‌شود: نویز دمایی^۴ و اثر ساقمه‌ای^۵.

• **آشفتگی هارمونیک^۶**: آشفتگی‌های هارمونیک در واقع نویزهای تصادفی نیستند بلکه آشفتگی‌هایی هستند که از منابع نزدیک بر روی سیستم افتدند. این نویزها می‌توانند به وسیله طراحی‌های مناسب حذف شوند. روش‌هایی که برای حذف این نویز استفاده می‌شوند مبارزند از پوشش محافظه^۷، زمین کردن^۸ مناسب و کاهش حسابت سیستم^۹ به نویز. از آنجا که آشفتگی‌های هارمونیک دارای فرکانس‌های مشخصی هستند، باعث ایجاد نوسانات نامیرا^{۱۰} در سیگنال و ایجاد ضربه^{۱۱} در طیف فرکانسی^{۱۲} می‌شوند. این رفتار نکین^{۱۳} باعث می‌شود که نوع آن‌ها با نویزهای دیگر فرق کند.

• **نویز صورتی^{۱۴}** یا نویز $\frac{1}{f}$ در بررسی سیستم‌ها نویز واقعی سفید نیست بلکه «صورتی» است. به این معنا که دارای فرکانس قطع است. این فرکانس قطع باعث می‌شود که واریانس نویز محدود شود. طیف توان این نویز با آهنگ $\frac{1}{f}$ کاهش پیدا می‌کند. توان نویز $\frac{1}{f}$ بستگی به نحوه تولید آن دارد و از وسیله‌ای به وسیله دیگر متفاوت است.

• **نویز آشوبی^{۱۵}**: این نویز می‌تواند توسط ماشین‌هایی که دارای فست گردنده^{۱۶} و بالهای تیز^{۱۷} می‌باشد تولید گردد. معمولاً این نویز

نرمال در نظر می‌گیرند. البته در شرایطی که تعداد نمونه‌های «متغیر تصادفی» نویز کم باشد، ممکن است توزیع‌های دیگری نیز متنظر قرار گیرد.

تصادفی بودن نویز سبب می‌شود که تابع توزیع احتمال آن از نوع «نرمال یا گاوسی با میانگین صفر» و به صورت $N(0, \sigma_n^2)$ در نظر گرفته شود^[۹]. بنابراین برای توصیف نویز از مقادیر مرتع آن استفاده می‌شود. مقدار مؤثر^{۱۸} نویز از جذر میانگین مربعات^{۱۹} آن به دست می‌آید. البته این پارامتر هیچ اطلاعاتی در مورد چگونگی تغییر مقدار نویز با زمان و یا اجزای فرکانسی آن نمی‌دهد. اگر ویژگی‌های آماری نویز مانند واریانس^{۲۰} یا انحراف استاندارد و یا مقدار مؤثر آن با زمان تغییر نکند به آن نویز ایستا^{۲۱} گفته می‌شود^[۹].

در سیستم‌هایی که چند منبع نویز وجود داشته باشد نویز کلی می‌تواند به صورت مجموع نویزهای مختلف در نظر گرفته شود. اگر این نویزها مستقل^{۲۲} از یکدیگر باشند می‌توان مقدار مؤثر را به صورت جمع مقدارهای مؤثر تک تک منابع نویز در نظر گرفت^[۴۱ ۳۹].

۳-۲ انواع نویز

نویزها بیشتر بر اساس تغیرات زمانی و فرکانسی خود از یکدیگر مستقل می‌شوند. در شبکه عصبی بر پایه توانع شعاعی گرانولی، با نویزهای سروکار داریم که از نوع سیگنال‌های «گسته در زمان WSS» تصادفی^{۲۳} می‌باشند. یک گروه مهم از این سیگنال‌ها، سیگنال‌های WSS^{۲۴} است. یک سیگنال «گسته در زمان تصادفی» مانند دنباله نویزی $(n_r^{(t)})_{r \in N}$ را بک سیگنال WSS گویند اگر داشته باشیم:

$$E(n_r^{(t)}) = a \text{ constant value} \quad \forall r \in [-\infty, \infty] \quad (1)$$

$$E(n_p^{(t)} n_q^{(t)}) = E(n_{p+r}^{(t)} n_{q+r}^{(t)}), \quad \forall p, q, r \in N \quad (2)$$

از فرمول‌های (۱) و (۲) نتیجه می‌گیریم که برای WSS بودن یک سیگنال «گسته در زمان تصادفی» مانند دنباله نویزی $(n_r^{(t)})_{r \in N}$ میانگین آن به ازای هر مقدار ϵ باید ثابت باشد.

$$E((n_r^{(t)})^2) = a \text{ constant value} \Rightarrow Var(n_r^{(t)}) = \\ a \text{ constant value} \quad (3)$$

از فرمول (۳) نتیجه می‌گیریم که برای WSS بودن یک سیگنال «گسته در زمان تصادفی» مانند دنباله نویزی $(n_r^{(t)})_{r \in N}$ واریانس آن

^۱ Effective

^۲ Root Mean Square (RMS)

^۳ واریانس معرف انرژی نویز است

^۴ Static

^۵ نویزهای مستقل هستند که میانگین حاصل ضرب دوی نویزها صفر شود

^۶ Stochastic Discrete Time Signal

^۷ Wide-Sense Stationary

^۸ White Noise
^۹ Power Spectral Density
^{۱۰} Power Spectrum
^{۱۱} Thermal Noise
^{۱۲} Shot Noise
^{۱۳} Harmonic Disturbance or Harmonic Oscillation
^{۱۴} Shield
^{۱۵} Earthing
^{۱۶} System Sensitivity Reduction
^{۱۷} Undamped Oscillations
^{۱۸} Impulse
^{۱۹} Frequency Spectrum
^{۲۰} Singularity Behavior
^{۲۱} Pink Noise or Flicker Noise
^{۲۲} Chaotic Noise
^{۲۳} Rotating part
^{۲۴} Blades

۳- معرفی شبکه عصبی RBF

ماتریس $X^{(t)}$ سطحی ورودی شبکه عصبی است که به شکل بک دسته داده ورودی به آن وارد می‌شود. و ماتریس $N^{(t)}$ نویز اضافه شده به این دسته داده ورودی می‌باشد. ماتریس $w^{j,(t)}$ شامل وزن‌های لایه پنهان شکه و ماتریس‌های $c^{j,(t)}$ و $t^{(t)}$ به ترتیب شامل مقادیر مرکز و انحراف استاندارد «توانع فعال‌ساز گاوسی نویز زام لایه پنهان شکه»^{۱۲} می‌باشند. اندیس‌های j و t به صورت زیر تعریف می‌گردند [۲۳]:

- برای تعداد خوشها^{۱۳} یا تعداد نویزهای لایه میانی داریم: $j = 1, 2, \dots, m$
- برای ابعاد ورودی‌ها داریم: $r = 1, 2, \dots, n$
- برای شماره نسونهای ورودی داریم: $t = 1, 2, \dots, T$

همچنین مقادیر اولیه مركّب توانع فعال‌ساز گاوسی نویزهای لایه پنهان، یعنی (0) معادل $c^{j,(0)}$ در نظر گرفته می‌شود. تابع ψ توانع فعال‌ساز گاوسی نویزهای لایه میانی است. ترم بکار رفته در اینجا ترم اقلیدسی می‌باشد. خروجی اولیه نویز زام لایه میانی یعنی $o^{j,(0)}$ را می‌توان به وسیله فرمول زیر بدست آورد [۲۴-۲۳]:

$$o^{j,(0)} = \psi \left[\sum_{r=1}^n \left(\frac{(x_r^{(0)} + n_r^{(0)} - c_r^{j,(0)})^2}{\sigma_r^{j,(0)}} \right) \right] = \psi \left[\sum_{r=1}^n (u_r^{j,(0)})^2 \right] = \psi(d^{j,(0)}) = \exp \left(-\frac{1}{2} d^{j,(0)} \right) \quad (5)$$

شکل ماتریسی متغیرهای به کار رفته بارت است از:

$$X^{(t)} = \begin{bmatrix} x_1^{(t)} \\ x_2^{(t)} \\ \vdots \\ x_n^{(t)} \end{bmatrix}_{n \times 1}, \quad N^{(t)} = \begin{bmatrix} n_1^{(t)} \\ n_2^{(t)} \\ \vdots \\ n_n^{(t)} \end{bmatrix}_{n \times 1}, \quad c^{j,(t)} = \begin{bmatrix} c_1^{j,(t)} \\ c_2^{j,(t)} \\ \vdots \\ c_n^{j,(t)} \end{bmatrix}_{n \times 1} = w^{j,(t)} = \begin{bmatrix} w_1^{j,(t)} \\ w_2^{j,(t)} \\ \vdots \\ w_n^{j,(t)} \end{bmatrix}_{n \times 1}, \quad \sigma^{j,(t)} = \begin{bmatrix} \sigma_1^{j,(t)} \\ \sigma_2^{j,(t)} \\ \vdots \\ \sigma_n^{j,(t)} \end{bmatrix}_{n \times 1} \quad (6)$$

برای مقادیر وزن‌های اتصال بین لایه ورودی و لایه پنهان شکه، ماتریس زیر را خواهیم داشت:

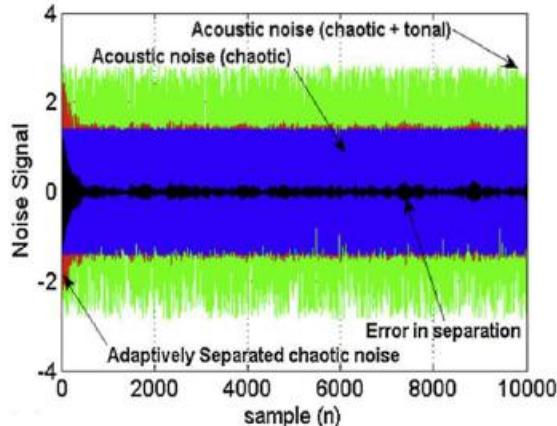
$$W^{(t)} = [w^{1,(t)} \quad w^{2,(t)} \quad \dots \quad w^{m,(t)}]_{1 \times m} = \begin{bmatrix} w_1^{1,(t)} & w_1^{2,(t)} & \dots & w_1^{m,(t)} \\ w_2^{1,(t)} & w_2^{2,(t)} & \dots & w_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ w_n^{1,(t)} & w_n^{2,(t)} & \dots & w_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (7)$$

برای مقادیر مرکز توانع فعال‌ساز نویزهای لایه پنهان، ماتریس زیر را خواهیم داشت:

¹² Gaussian activation functions of the j^{th} neuron in the hidden layer of the neural network

¹³ Clusters

با پیک ثُن صدا^{۱۴} ترکیب می‌گردد که واسن به سرعت بخشن قست گردان ماشین می‌باشد. بخش آشوبی نویز مربوط به برخورد لبه‌های تیز به هوای اطراف می‌باشد [۹].



شکل ۱. نمودار نیزهای نویز حاصل از ترکیب بخش آشوبی و ثُن صدا، پیش و پس از جداسازی این دو بخش، در دامنه زمان [۹]

۴-۲ کاهش اثر نویز

پدیده نویز در کنترل سیستم‌های مختلف مشکلی عمومی است و سیستم‌های هوشمند بوزیره سیستم‌های هوشمند نوع ^۲ [۱۱، ۷، ۶] که در آن‌ها مذکور عدم قطعیت به خوبی صورت می‌پذیرد، در این جمله وارد شده‌اند. تشخیص نویز^۳ و حذف نویز^۴ در سیاری از زمینه‌ها مانند برداش تصویر در کنار کاهش اثر نویز از اهمیت بالایی برخوردارند. با وجود پیشرفت در طراحی شبکه‌های عصبی، ارائه روش‌هایی که نیاز به دوره آموزش کمتری دارند هنوز مفید است. برخی از این روش‌ها در اینجا آورده شده است:

- استفاده از فیلتر غیرخطی «کاهش نویز ضربه فازی»^۵ [۱۴، ۱۳]
- به کار بردن روش موجک^۶ [۱۲]
- الگوریتم فیلتر خطی^۷ [v]FXLMS^۸
- الگوریتم کنترل با فیلتر غیرخطی^۹ [۱۵]VFXLMS^{۱۰}
- انواع شبکه‌های عصبی مانند شبکه عصبی RBF گرانولی [۲۰، ۱۸]
- و شبکه عصبی ارتباط تابعی^{۱۱} [۹]
- سیستم‌های منطق فازی نوع ^{۱۰} [۱۰]
- که به عنوان نمونه می‌توان با شبکه عصبی فازی نوع ^{۱۱} بازمای^{۱۲} [۷] آن را پیاده‌سازی نمود.

¹ Tonal

² Type 2 Intelligent Systems

³ Noise Detection

⁴ Noise Canceling

⁵ Fuzzy Impulse Noise Reduction Method (FINRM)

⁶ Wavelet

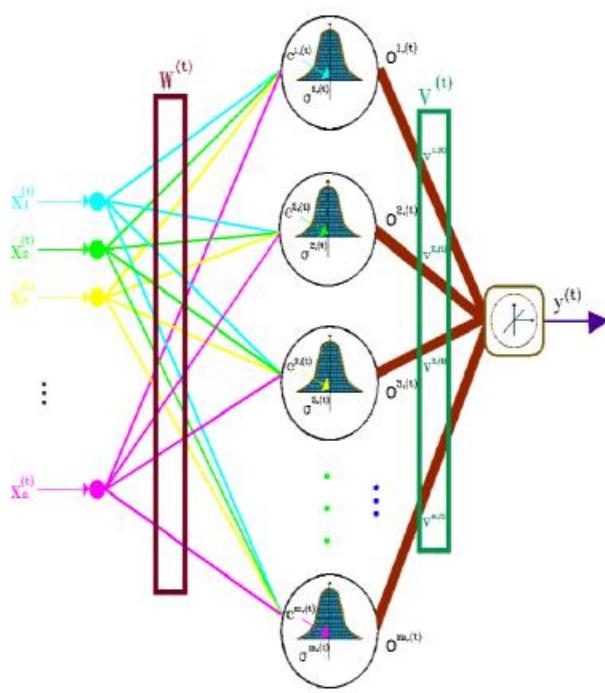
⁷ Filtered-X Least Mean Square

⁸ Volterra Filtered-X Least Mean Square

⁹ Function Link Artificial Neural Network (FLANN)

¹⁰ Type-2 Fuzzy Logic Systems (T2FLSs)

¹¹ Interval Type-2 Fuzzy Neural Network



شکل ۲. یک شبکه عصبی

۱-۳ روش‌های آموزش بکار رفته در شبکه عصبی RBF

برای آموزش پارامترهای غیرخطی لایه میانی که «مرکز» و «انحراف استاندارد» توانع فعال ساز گاوسی می‌باشد می‌توان از دو روش آموزش یکی از نوع آموزش می‌سربرست^۱ [۳۳] یعنی «الگوریتم خوشبندی K-Means» با خودش^۲ [۲۳، ۳۷] و دیگری از نوع آموزش با سربرست^۳ [۳۳] یعنی «گرادیان نزولی» استفاده نمود[۲۳، ۳۵]

۲-۳ الگوریتم خوشبندی K-Means با m خوشه

گام‌های الگوریتم برای آموزش مرکز توانع فعال ساز گاوسی^۱ به شرح زیر است و کاملاً مشابه الگوریتم آموزش «انحراف استاندارد آنها» می‌باشد، جز آنکه در الگوریتم آموزش «انحراف استاندارد»، به جای «مرکز» توانع فعال ساز گاوسی^۲ یعنی $c_r^{j,(t)}$ ، «انحراف استاندارد» یعنی $\sigma_r^{j,(t)}$ جایگزین می‌گردد[۲۳، ۳۷]

۱. به دو پارامتر «مرکز» یا «انحراف استاندارد» توانع فعال ساز گاوسی مربوط به تُرون‌های لایه میانی، مقادیر تصادفی اولیه به شکل $c_r^{j,(0)}$ و $\sigma_r^{j,(0)}$ و در بازه $[0, 1]$ نسبت می‌دهیم. برای این دو پارامتر یعنی $c_r^{j,(t)}$ و $\sigma_r^{j,(t)}$ اندیس‌های $j = 2$ و $t = 1, 2, \dots, T$ همانند گذشته تعریف می‌گرددند.

۲. بردار ورودی آموزشی جدید را اعمال می‌کیم.

$$X^{(t)} + N^{(t)} = [(x_1^{(t)} + n_1^{(t)}) (x_2^{(t)} + n_2^{(t)}) \dots (x_n^{(t)} + n_n^{(t)})] \quad (14)$$

$$\begin{aligned} C^{(t)} &= [c^{1,(t)} \ c^{2,(t)} \ \dots \ c^{m,(t)}]_{1 \times m} = \\ &\begin{bmatrix} c_1^{1,(t)} & c_1^{2,(t)} & \dots & c_1^{m,(t)} \\ c_2^{1,(t)} & c_2^{2,(t)} & \dots & c_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ c_n^{1,(t)} & c_n^{2,(t)} & \dots & c_n^{m,(t)} \end{bmatrix}_{n \times m} \end{aligned} \quad (1)$$

و برای مقادیر انحراف استاندارد این تُرون‌ها، ماتریس زیر را خواهیم داشت:

$$\begin{aligned} \Sigma^{(t)} &= [\sigma^{1,(t)} \ \sigma^{2,(t)} \ \dots \ \sigma^{m,(t)}]_{1 \times m} = \\ &\begin{bmatrix} \sigma_1^{1,(t)} & \sigma_1^{2,(t)} & \dots & \sigma_1^{m,(t)} \\ \sigma_2^{1,(t)} & \sigma_2^{2,(t)} & \dots & \sigma_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_n^{1,(t)} & \sigma_n^{2,(t)} & \dots & \sigma_n^{m,(t)} \end{bmatrix}_{n \times m} \end{aligned} \quad (2)$$

خروجی لایه پنهان شبکه عصبی برای یک داده ورودی برابر خواهد بود با:

$$\begin{aligned} O^{(t)} &= [o^{1,(t)} \ o^{2,(t)} \ \dots \ o^{m,(t)}] \\ &= [\psi(X^{(t)}, N^{(t)}, C^{1,(t)}, \Sigma^{1,(t)}) \ \psi(X^{(t)}, N^{(t)}, C^{2,(t)}, \Sigma^{2,(t)}) \ \dots \\ &\quad \dots \ \psi(X^{(t)}, N^{(t)}, C^{m,(t)}, \Sigma^{m,(t)})] \end{aligned} \quad (1)$$

$$O^{(t)} = \left[\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{1,(t)}}{\sigma_r^{1,(t)}} \right)^2 \right] \ \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{2,(t)}}{\sigma_r^{2,(t)}} \right)^2 \right] \ \dots \ \dots \ \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{m,(t)}}{\sigma_r^{m,(t)}} \right)^2 \right] \right] \quad (11)$$

اکنون خروجی نهایی شبکه عصبی برای یک نمونه داده ورودی برابر خواهد بود با[۲۳]:

$$y_N^{(t)} = \sum_{j=1}^m (v^{j,(t)} \times o^{j,(t)}) \quad (12)$$

آنچه که $v^{j,(t)}$ وزن اتصال بین لایه میانی و لایه خروجی برای زمین تُرون لایه پنهان است و یک پارامتر خطی می‌باشد. در نهایت در یک فرمول کلی برای هر یک از $t = 1, 2, \dots, T$ نمونه داده ورودی خواهیم داشت[۲۳]:

$$\begin{aligned} y_N^{(t)} &= G(X^{(t)}, N^{(t)}, C^{(t)}, \Sigma^{(t)}, V^{(t)}) = \\ &\sum_{j=1}^m [v^{j,(t)} \times \psi(X^{(t)}, N^{(t)}, C^{j,(t)}, \Sigma^{j,(t)})] = \\ &\sum_{j=1}^m (v^{j,(t)} \times o^{j,(t)}) \end{aligned} \quad (13)$$

$V^{(t)}$ ماتریس وزن‌های اتصال بین لایه میانی که و لایه خروجی می‌باشد[۲۳]

¹ Unsupervised Learning
² Supervisory Learning

$$\begin{aligned} & (\mathbf{X}^{(t)} + \mathcal{N}^{(t)}) \times \mathbf{U}^{(t)} = \\ & [(x_1^{(t)} + n_1^{(t)}) \cdot u_1^{1,(t)} + (x_2^{(t)} + n_2^{(t)}) \cdot u_2^{1,(t)} + \dots + (x_n^{(t)} + n_n^{(t)}) \cdot u_n^{1,(t)} \\ & (x_1^{(t)} + n_1^{(t)}) \cdot u_1^{2,(t)} + (x_2^{(t)} + n_2^{(t)}) \cdot u_2^{2,(t)} + \dots + (x_n^{(t)} + n_n^{(t)}) \cdot u_n^{2,(t)} \dots \\ & (x_1^{(t)} + n_1^{(t)}) \cdot u_1^{m,(t)} + (x_2^{(t)} + n_2^{(t)}) \cdot u_2^{m,(t)} + \dots + (x_n^{(t)} + n_n^{(t)}) \cdot u_n^{m,(t)}] \end{aligned} \quad (21)$$

هر درایه ماتریس حاصلضرب مربوط به یک خوش است و هر چه مقدار یک درایه بزرگ باشد احتمال تعلق بردار ورودی به آن خوش بیشتر می‌گردد. قطعی ترین حالت زمانی است که به جز یک درایه بقیه آنها صفر باشد و بدترین وضعیت زمانی رخ می‌دهد که مقدار دو یا چند درایه مساوی گردد که در این صورت تعلق بردار ورودی به یکی از خوش‌هایی که مقدار درایه مربوط به آنها مساوی است، به صورت تصادفی تعیین می‌گردد.

۴. تابع هزینه می‌تواند توسط رابطه زیر تعریف گردد:

$$\begin{aligned} J^{(t)} = \sum_{j=1}^m J_j^{(t)} &= \sum_{j=1}^m \| \mathbf{X}^{(t)} + \mathcal{N}^{(t)} - \mathbf{c}^{j,(t)} \|_2 \\ &= \sum_{j=1}^m \sqrt{\sum_{r=1}^n (x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})^2} \end{aligned} \quad (22)$$

۵. مرکز خوش $\mathbf{c}^{j,(t)}$ را به کمک رابطه (۲۳) و انحراف استاندارد خوش $\sigma^{j,(t)}$ را به وسیله رابطه (۲۴) تغییر می‌دهیم.

$$\mathbf{c}^{j,(t+1)} = \mathbf{c}^{j,(t)} + \lambda_c^{(t)}(t)(\mathbf{X}^{(t)} + \mathcal{N}^{(t)} - \mathbf{c}^{j,(t)}) \quad (23)$$

$$\sigma^{j,(t+1)} = \sigma^{j,(t)} + \lambda_\sigma^{(t)}(t)(\mathbf{X}^{(t)} + \mathcal{N}^{(t)} - \mathbf{c}^{j,(t)}) \quad (24)$$

پارامترهای $\lambda_c^{(t)}$ و $\lambda_\sigma^{(t)}$ ضوابط آموزش تطبیقی هستند که توسط یک تابع خطی از t به شکل زیر آموزش می‌بندند.

$$\lambda_c^{(t)} = \lambda_c^{(0)}(1 - \frac{t}{T}) \quad (25)$$

$$\lambda_\sigma^{(t)} = \lambda_\sigma^{(0)}(1 - \frac{t}{T}) \quad (26)$$

پارامترهای $\lambda_c^{(0)}$ و $\lambda_\sigma^{(0)}$ ضوابط آموزش تطبیقی اولیه، پارامتر t دوره آموزشی فعلی و T تعداد کل تکرار برای آموزش است.

۶. شرط خانه حلقه^۱ می‌تواند به یکی از سه شکل زیر در نظر گرفته شود که در صورت برقراری یکی از آنها آموزش پایان می‌یابد و در غیر اینصورت به گام دو برمی‌گردد.

الف) بعد از طی تعداد تعیین شده‌ای از تکرار.

ب) در صورتی که برای تابع هزینه مقدار معین بدست آمده باشد.

ج) بهبود تابع هزینه نسبت به تکرار فلی کمتر از یک حد آستانه معین باشد.

۳. به یکی از دو روش زیر، تعلق بردار ورودی آموزشی جدید $X^{(t)} + \mathcal{N}^{(t)}$ را به یک خوش تعیین می‌کیم.

۳.۱. نزدیکترین مرکز تابع فعال‌ساز گاووسی، نسبت به برهمای $X^{(t)} + \mathcal{N}^{(t)}$ را به دست می‌آوریم. در اینجا از فاصله افلاطی به عنوان معیار نزدیکی بین بردار ورودی $X^{(t)} + \mathcal{N}^{(t)}$ و مرکز خوش $\mathbf{c}^{j,(t)}$ به صورت زیر استفاده می‌شود:

$$J_j^{(t)} = \sqrt{(\| X^{(t)} + \mathcal{N}^{(t)} - \mathbf{c}^{j,(t)} \|_2)} = \sqrt{\sum_{r=1}^n (x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})^2} \quad (15)$$

۳.۲. تعلق هر بردار ورودی به یک خوش، را با استفاده از ماتریس تعلق^۲ \mathbf{U} به ابعاد $n \times m$ تعیین می‌کیم. در این ماتریس دودویی، درایه $u_r^{j,(t)}$ برابر یک است اگر r آمین داده بردار ورودی یعنی $x_r^{(t)} + n_r^{(t)}$ به گروه ز تعلق داشته باشد و در غیر این صورت برابر صفر حواهد بود. این ماتریس می‌تواند به صورت زیر توصیف شود:

$$\mathbf{U}^{(t)} = \begin{bmatrix} u_1^{1,(t)} & u_1^{2,(t)} & \dots & u_1^{m,(t)} \\ u_2^{1,(t)} & u_2^{2,(t)} & \dots & u_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ u_n^{1,(t)} & u_n^{2,(t)} & \dots & u_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (16)$$

که در آن داریم:

$$u_r^{j,(t)} = \begin{cases} 1 & \text{if } \| x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)} \|_2 \leq \| x_r^{(t)} + n_r^{(t)} - c_r^{k,(t)} \|_2 \\ 0 & \text{otherwise} \end{cases} \quad (17)$$

$\forall k = 1, 2, \dots, m, \forall r = 1, 2, 3, \dots, n | k \neq j$

ماتریس تعلق دودویی \mathbf{U} لازم است که هر دو ویژگی (۱۸) و (۱۹) را داشته باشد.

$$\sum_{j=1}^m u_r^{j,(t)} = 1 \quad \forall r = 1, 2, 3, \dots, n \quad (18)$$

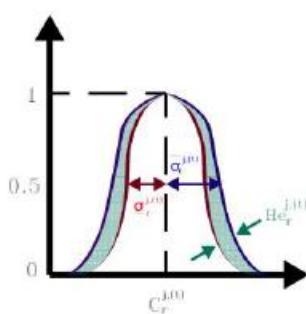
$$\sum_{r=1}^n \sum_{j=1}^m u_r^{j,(t)} = n \quad (19)$$

از آنجایی که هر بردار ورودی تنها می‌تواند به یک خوش تعلق داشته باشد، با ضرب بردار ورودی آموزشی جدید $X^{(t)} + \mathcal{N}^{(t)}$ در ماتریس تعلق \mathbf{U} به ماتریس زیر می‌رسیم:

$$\begin{aligned} & (\mathbf{X}^{(t)} + \mathcal{N}^{(t)}) \times \mathbf{U}^{(t)} \\ &= [(x_1^{(t)} + n_1^{(t)}) (x_2^{(t)} + n_2^{(t)}) \dots (x_n^{(t)} + n_n^{(t)})]_{1 \times n} \\ &\times \begin{bmatrix} u_1^{1,(t)} & u_1^{2,(t)} & \dots & u_1^{m,(t)} \\ u_2^{1,(t)} & u_2^{2,(t)} & \dots & u_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ u_n^{1,(t)} & u_n^{2,(t)} & \dots & u_n^{m,(t)} \end{bmatrix}_{n \times m} \end{aligned} \quad (20)$$

¹ End of loop condition

² Membership matrix



شکل ۲. تابع فعال ساز گاوسی گرانولی در نرونهای لایه میانی

۱. نرونهای دارای بیشترین تکرار را با $c_r^{j(t)}$ نشان می‌دهند که مرکز یک تابع گاوسی است. در پیاده سازی، مراکز تابع گاوسی در یک ماتریس به نام $(mean^{(t)})^T$ ذخیره می‌گردند. تعداد سطرهای این ماتریس همان تعداد ورودی‌های شبکه عصبی و تعداد ستونهای آن برابر تعداد نرونهای لایه میانی است. این مقدار بازه‌ای نیستند [۲۳، ۱۸].

$$(mean^{(t)})^T = C^{(t)} = \begin{bmatrix} c^{1,(t)} & c^{2,(t)} & \dots & c^{m,(t)} \end{bmatrix}_{1 \times m} = \begin{bmatrix} c_1^{1,(t)} & c_1^{2,(t)} & \dots & c_1^{m,(t)} \\ c_2^{1,(t)} & c_2^{2,(t)} & \dots & c_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ c_n^{1,(t)} & c_n^{2,(t)} & \dots & c_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (۳۷)$$

۲. عدم قطعیت اندازه‌گیری شده را با متغیر $Entropy^{(t)}$ [۲۳] مدل می‌کنند که در ارتباط با انحراف استاندارد است. انحراف استاندارد دارای مقادیر بازه‌ای است و کران پائین آن در یک ماتریس به نام $(STDEVleft^{(t)})^T$ و کران بالا در ماتریس دیگری به نام $(STDEVright^{(t)})^T$ ذخیره می‌گردد. در هر دو ماتریس تعداد سطرهای همان تعداد ورودی‌های شبکه عصبی و تعداد ستونها تعداد نرونهای لایه میانی است [۲۶، ۱۸]. هر چه میزان نویز تزریق شده به داده‌ها بیشتر باشد فاصله کران پائین انحراف استاندارد از کران بالای آن بیشتر می‌گردد و در نتیجه $Entropy^{(t)}$ بزرگتر خواهد بود. این مقدار عدم قطعیت بزرگتر همراه است [۴].

$$(STDEVleft^{(t)})^T = \underline{\Sigma}^{(t)} = \begin{bmatrix} \underline{\sigma}^{1,(t)} & \underline{\sigma}^{2,(t)} & \dots & \underline{\sigma}^{m,(t)} \end{bmatrix}_{1 \times m} = \begin{bmatrix} \underline{\sigma}_1^{1,(t)} & \underline{\sigma}_1^{2,(t)} & \dots & \underline{\sigma}_1^{m,(t)} \\ \underline{\sigma}_2^{1,(t)} & \underline{\sigma}_2^{2,(t)} & \dots & \underline{\sigma}_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \underline{\sigma}_n^{1,(t)} & \underline{\sigma}_n^{2,(t)} & \dots & \underline{\sigma}_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (۳۸)$$

۱-۱-۳ الگوریتم پس انتشار خطای استفاده از گرادیان نزولی^۱

الگوریتم پس انتشار خطای برای n ورودی و m خروجی و یک خروجی، بر اساس مجموع مربuat خطای صورت زیر محاسبه می‌گردد در این الگوریتم نرخ آموزش می‌تواند برای تمام پارامترها بکسان با مقاومت در نظر گرفته شود [۳۵، ۳۳].

$$e^{(t)} = d^{(t)} - y_N^{(t)}, \quad E^{(t)} = \frac{1}{2} (e^{(t)})^2 \quad (۳۷)$$

برای وزنهای لایه خروجی که پارامترهای خطی می‌باشند داریم:

$$\Delta v^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial v^{j,(t)}} = -\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial y^{(t)}} \times \frac{\partial y^{(t)}}{\partial v^{j,(t)}} \quad (۴۸)$$

$$\Delta v^{j,(t)} = -\eta \times e^{(t)} \times (-1) \times o^{j,(t)} \quad (۴۹)$$

$$v^{j,(t+1)} = v^{j,(t)} + \Delta v^{j,(t)} = v^{j,(t)} + \eta e^{(t)} o^{j,(t)} \quad (۵۰)$$

برای پارامترهای لایه میانی خواهیم داشت:

$$\Delta c_r^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial c_r^{j,(t)}} = -\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial y^{(t)}} \times \frac{\partial y^{(t)}}{\partial o^{j,(t)}} \times \frac{\partial o^{j,(t)}}{\partial d^{j,(t)}} \times \frac{\partial d^{j,(t)}}{\partial c_r^{j,(t)}} \quad (۵۱)$$

$$\Delta c_r^{j,(t)} = -\eta \times e^{(t)} \times (-1) \times v^{j,(t)} \times \frac{o^{j,(t)} \times d^{j,(t)}}{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}} \quad (۵۲)$$

$$c_r^{j,(t+1)} = c_r^{j,(t)} + \Delta c_r^{j,(t)} = c_r^{j,(t)} + \eta e^{(t)} v^{j,(t)} \frac{o^{j,(t)} \times d^{j,(t)}}{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}} \quad (۵۳)$$

$$\Delta \sigma_r^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial \sigma_r^{j,(t)}} = -\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial y^{(t)}} \times \frac{\partial y^{(t)}}{\partial o^{j,(t)}} \times \frac{\partial o^{j,(t)}}{\partial d^{j,(t)}} \times \frac{\partial d^{j,(t)}}{\partial \sigma_r^{j,(t)}} \quad (۵۴)$$

$$\Delta \sigma_r^{j,(t)} = -\eta \times e^{(t)} \times (-1) \times v^{j,(t)} \times \frac{o^{j,(t)} \times d^{j,(t)}}{\sigma_r^{j,(t)}} \quad (۵۵)$$

$$\sigma_r^{j,(t+1)} = \sigma_r^{j,(t)} + \Delta \sigma_r^{j,(t)} = \sigma_r^{j,(t)} + \eta e^{(t)} v^{j,(t)} \frac{d^{j,(t)} \times o^{j,(t)}}{\sigma_r^{j,(t)}} \quad (۵۶)$$

۴- معرفی شبکه عصبی بر پایه تابع فعال ساز گاوسی گرانولی

نمونه‌ای از تابع فعال ساز گاوسی گرانولی بکار رفته در نرونهای لایه میانی، در شکل ۳ نشان داده شده است. به این نوع تابع، تابع گاوسی مدل ابر^۲ گفته می‌شود و دارای سه مشخصه عددی می‌باشد. این سه مشخصه عددی (۱) مرکز تابع گاوسی (۲) عدم قطعیت اندازه‌گیری شده و (۳) بالاترین مقدار عدم قطعیت هستند که به ترتیب و در ادامه مطلب تعریف شده‌اند [۲۳، ۲۱، ۱۷].

^۱ Entropy (En)

^۲ Cloud model

ماتریس مقادیر ثابت بوده و بازه‌ای بسته است. مقادیر انحرافی استاندارد که نامعنی می‌باشد و به صورت بازه $[\bar{\sigma}_r^{j,(t)} \quad \underline{\sigma}_r^{j,(t)}]$ در نظر گرفته می‌شود نیز در دو ماتریس کران پائین و کران بالا نگهداری می‌گردد.

یک شبکه عصبی RBF گرانولی با استفاده ازتابع گاوسی مدل ابر، یک شبکه عصبی گرانولی با مقادیر انحرافی استاندارد غیرقطیعی هم نامیده می‌شود^[۵]. خروجی هر ترnon لایه میانی در این شبکه عصبی گرانولی دارای کران پائین و کران بالا بوده و آن را می‌توان به صورت یک بازه $[\bar{\sigma}_r^{j,(t)} \quad \underline{\sigma}_r^{j,(t)}]$ نشان داد. ماتریس‌های کران پائین و کران بالای خروجی لایه پنهان شبکه عصبی RBF گرانولی برای یک دسته داده ورودی برابر خواهد بود با^[۲۳]:

$$\underline{\sigma}^{(t)} = [\underline{\sigma}^{1,(t)} \quad \underline{\sigma}^{2,(t)} \quad \dots \quad \underline{\sigma}^{m,(t)}] \\ = [\psi(X^{(t)}, N^{(t)}, c^{1,(t)}, \underline{\sigma}^{1,(t)}) \quad \psi(X^{(t)}, N^{(t)}, c^{2,(t)}, \underline{\sigma}^{2,(t)}) \dots \\ \dots \quad \psi(X^{(t)}, N^{(t)}, c^{m,(t)}, \underline{\sigma}^{m,(t)})] \quad (۴۳)$$

$$\bar{\sigma}^{(t)} = \left[\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{1,(t)}}{\sigma_r^{1,(t)}} \right)^2 \right] \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{2,(t)}}{\sigma_r^{2,(t)}} \right)^2 \right] \dots \right. \\ \left. \dots \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{m,(t)}}{\sigma_r^{m,(t)}} \right)^2 \right] \right] \quad (۴۴)$$

$$\bar{\sigma}^{(t)} = [\bar{\sigma}^{1,(t)} \quad \bar{\sigma}^{2,(t)} \quad \dots \quad \bar{\sigma}^{m,(t)}] \\ = [\psi(X^{(t)}, N^{(t)}, c^{1,(t)}, \bar{\sigma}^{1,(t)}) \quad \psi(X^{(t)}, N^{(t)}, c^{2,(t)}, \bar{\sigma}^{2,(t)}) \dots \\ \dots \quad \psi(X^{(t)}, N^{(t)}, c^{m,(t)}, \bar{\sigma}^{m,(t)})] \quad (۴۵)$$

$$\bar{\sigma}^{(t)} = \left[\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{1,(t)}}{\sigma_r^{1,(t)}} \right)^2 \right] \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{2,(t)}}{\sigma_r^{2,(t)}} \right)^2 \right] \dots \right. \\ \left. \dots \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{m,(t)}}{\sigma_r^{m,(t)}} \right)^2 \right] \right] \quad (۴۶)$$

در شکل ۴ یک شبکه عصبی RBF گرانولی که بر پایه توابع فعال‌ساز گرانولی بتا گردیده، نشان داده شده است. در این شبکه عصبی، انحراف استاندارد بازه‌ای در توابع فعال‌ساز گرانولی لایه پنهان و وزن‌های بازه‌ای در لایه خروجی، انعطاف‌پذیری و پایداری آن در مقابل نویز را به مقادیر زیادی افزایش می‌دهند.

$$(STDEVright^{(t)})^T = \Sigma^{(t)} = \\ [\bar{\sigma}^{1,(t)} \quad \bar{\sigma}^{2,(t)} \quad \dots \quad \bar{\sigma}^{m,(t)}]_{1 \times m} = \\ \begin{bmatrix} \bar{\sigma}_1^{1,(t)} & \bar{\sigma}_1^{2,(t)} & \dots & \bar{\sigma}_1^{m,(t)} \\ \bar{\sigma}_2^{1,(t)} & \bar{\sigma}_2^{2,(t)} & \dots & \bar{\sigma}_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\sigma}_n^{1,(t)} & \bar{\sigma}_n^{2,(t)} & \dots & \bar{\sigma}_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (۴۹)$$

$$Entropy^{(t)} = \Sigma^{(t)} - \underline{\Sigma}^{(t)} = \\ [\bar{\sigma}^{1,(t)} \quad \bar{\sigma}^{2,(t)} \quad \dots \quad \bar{\sigma}^{m,(t)}]_{1 \times m} - \\ [\sigma^{1,(t)} \quad \sigma^{2,(t)} \quad \dots \quad \sigma^{m,(t)}]_{1 \times m} \quad (۴۰)$$

$$Entropy^{(t)} = \begin{bmatrix} \bar{\sigma}_1^{1,(t)} & \bar{\sigma}_1^{2,(t)} & \dots & \bar{\sigma}_1^{m,(t)} \\ \bar{\sigma}_2^{1,(t)} & \bar{\sigma}_2^{2,(t)} & \dots & \bar{\sigma}_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\sigma}_n^{1,(t)} & \bar{\sigma}_n^{2,(t)} & \dots & \bar{\sigma}_n^{m,(t)} \end{bmatrix}_{n \times m} - \\ \begin{bmatrix} \sigma_1^{1,(t)} & \sigma_1^{2,(t)} & \dots & \sigma_1^{m,(t)} \\ \sigma_2^{1,(t)} & \sigma_2^{2,(t)} & \dots & \sigma_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_n^{1,(t)} & \sigma_n^{2,(t)} & \dots & \sigma_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (۴۱)$$

$$Entropy^{(t)} = \begin{bmatrix} \bar{\sigma}_1^{1,(t)} - \sigma_1^{1,(t)} & \bar{\sigma}_1^{2,(t)} - \sigma_1^{2,(t)} & \dots & \bar{\sigma}_1^{m,(t)} - \sigma_1^{m,(t)} \\ \bar{\sigma}_2^{1,(t)} - \sigma_2^{1,(t)} & \bar{\sigma}_2^{2,(t)} - \sigma_2^{2,(t)} & \dots & \bar{\sigma}_2^{m,(t)} - \sigma_2^{m,(t)} \\ \vdots & \vdots & \ddots & \vdots \\ \bar{\sigma}_n^{1,(t)} - \sigma_n^{1,(t)} & \bar{\sigma}_n^{2,(t)} - \sigma_n^{2,(t)} & \dots & \bar{\sigma}_n^{m,(t)} - \sigma_n^{m,(t)} \end{bmatrix}_{n \times m} \quad (۴۲)$$

۳. بالاترین مقدار عدم قطعیت را با هایبر انتروپی^[۲۳] نشان می‌دهند. هنگامی که کران‌های پائین و بالای انحراف استاندارد بعضی مقادیر $\sigma_r^{j,(t)}$ و $\bar{\sigma}_r^{j,(t)}$ برای هر تابع فعال‌ساز گرانولی آموزش داده می‌شود، مقدار He تغییر می‌کند. البته مقادیر $\underline{\sigma}_r^{j,(t)}$ و $\bar{\sigma}_r^{j,(t)}$ در تابع فعال‌ساز گرانولی، نسبت به خط افقی گذرنده از وسط محور عمودی سنجیده می‌شوند. مقدار He طبق شکل ۲ در جایی بوجود می‌آید که تابع فعال‌ساز گرانولی بهین ترین موقعت خود را دارد. منطقی است که با مقدار He نویز در مقادیر ورودی و پس از آموزش کران‌های پائین و بالای انحراف استاندارد، مقدار He بزرگتر بدست آید و بر عکس مقدار ضعیف تر نویز مقدار He کوچکتر را نتیجه دهد. در واقع بازه‌ای بودن انحراف استاندارد و وزن‌های لایه خروجی، عدم قطعیت حاصل از نویز در داده‌های ورودی را پوشش داده و ابزار غله بر آنها را در اختیار شبکه عصبی RBF گرانولی فراز می‌دهد^[۱۰].

همانطور که گفته شد، مقادیر مرکز تابع فعال‌ساز گاوسی گرانولی ترnon زیم لایه میانی، در یک بردار به نام $c^{(t)}$ ذخیره می‌گردد که تعداد درایم‌های آن برابر تعداد ورودی‌های سیستم می‌باشد. درایم‌های این

^۲ Uncertain standard deviation

^۱ Hyper Entropy (He)

رساندن و جمع کردن مقادیر $\underline{d}^{j,(t)}$ به ازای تمام ورودی‌های $x_r^{(t)} + n_r^{(t)}$ با ابعاد $r = 1, 2, \dots, n$ در تُرون زام لایه پنهان، مendar مثبت $\underline{d}^{j,(t)}$ به دست می‌آید. هنگامی که $\underline{d}^{j,(t)}$ در ضرب $\frac{1}{2}$ - ضرب $\exp\left(-\frac{1}{2}\underline{d}^{j,(t)}\right) = \frac{1}{\sigma^{(j,(t))}} e^{\left(\frac{-1}{2}\underline{d}^{j,(t)}\right)}$ واز حاصل ضرب تابع نسایی به صورت گرفته می‌شود؛ به دلیل کوچک شدن مخرج کسر، حاصل تقسیم بزرگ شده و کران بالای خروجی تابع گاوسی گرانولی یعنی $\underline{\sigma}^{j,(t)}$ که مقداری مثبت است، به دست می‌آید.

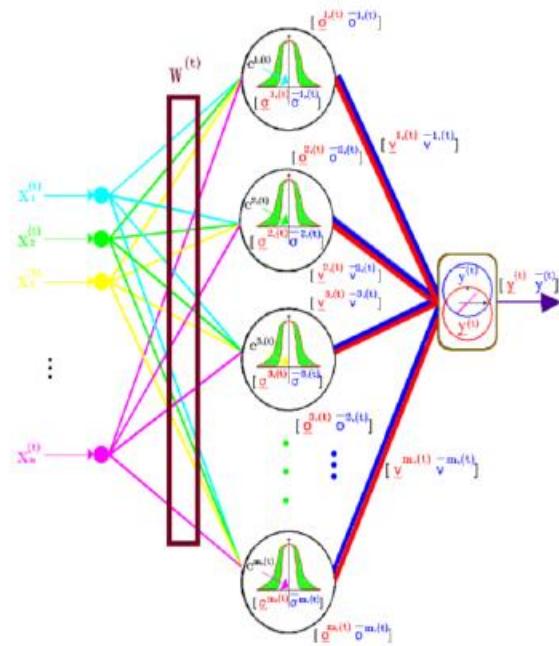
همانطور که مشاهده می‌گردد گاوسی بودن یک تابع فعال ساز گرانولی تقسیم می‌کند که کران پائین و کران بالای خروجی آن هبشه مثبت باشد. پس هر مendar متعلق به بازه $[\underline{v}^{j,(t)}, \underline{\sigma}^{j,(t)}]$ ، مendarی مثبت خواهد بود.

از طرف دیگر با توجه به این که s^j بازه تغییرات «مرکز وزن» اتصال بین لایه میانی و لایه خروجی برای زامین تُرون لایه پنهان، یعنی $v^{j,(t)}$ می‌باشد و از آنجا که در محاسبه کران پائین و کران بالای «وزن»‌های بازه‌ای در لایه خروجی، یعنی مقادیر $\underline{v}^{j,(t)}$ و $\overline{v}^{j,(t)}$ از قدر مطلق بازه این وزن‌ها، یعنی $|s^{j,(t)}|$ ، به صورت $|s^{j,(t)}| - |s^{j,(t)}|$ و $\underline{v}^{j,(t)} = v^{j,(t)} - |s^{j,(t)}|$ استفاده گردیده است؛ تقسیم می‌گردد که به ازای مقادیر منفی و مثبت «مرکز وزن»‌های بازه‌ای در لایه خروجی، یعنی $v^{j,(t)}$ کران پائین «وزن»‌های بازه‌ای در لایه خروجی، یعنی مendar $v^{j,(t)}$ هبشه کوچکتر از کران بالای «وزن»‌های بازه‌ای در لایه خروجی، یعنی مendar $\overline{v}^{j,(t)}$ باشد یعنی هبشه رابطه نامساوی به صورت $v^{j,(t)} < \overline{v}^{j,(t)}$ که معادل با رابطه نامساوی به شکل $|s^{j,(t)}| < v^{j,(t)} + |s^{j,(t)}|$ است؛ برقرار می‌باشد.

سرانجام، برای محاسبه خروجی نهایی شبکه عصبی RBF گرانولی چهار حالت زیر ممکن است رخدده:

- حالت اول: اگر $0 > |s^{j,(t)}| > v^{j,(t)}$ و $v^{j,(t)} > |s^{j,(t)}|$ باشد آن‌گاه $\underline{v}^{j,(t)} > 0$ و $\overline{v}^{j,(t)} < 0$ خواهد بود.
- حالت دوم: اگر $0 > |s^{j,(t)}| > v^{j,(t)}$ و $v^{j,(t)} < 0$ باشد آن‌گاه $\underline{v}^{j,(t)} < 0$ و $\overline{v}^{j,(t)} > 0$ خواهد بود.
- حالت سوم: اگر $0 < |s^{j,(t)}| < v^{j,(t)}$ و $v^{j,(t)} < |s^{j,(t)}|$ باشد آن‌گاه $\underline{v}^{j,(t)} < 0$ و $\overline{v}^{j,(t)} > 0$ خواهد بود.
- حالت چهارم: اگر $0 < |s^{j,(t)}| < v^{j,(t)}$ و $v^{j,(t)} < |s^{j,(t)}|$ باشد آن‌گاه $\underline{v}^{j,(t)} > 0$ و $\overline{v}^{j,(t)} < 0$ خواهد بود.

در حالت‌های اول، دوم و چهارم، کران پائین و کران بالای خروجی نهایی شبکه عصبی RBF گرانولی، به همراه پارامترهای خطي کران پائین و کران بالای لایه خروجی شبکه به این صورت خواهد بود[۲۳]:



شکل ۴. شبکه عصبی RBF گرانولی بر پایه تابع گاوسی گرانولی

محاسبه کران پائین خروجی یک تابع گاوسی گرانولی در لایه میانی به شکل زیر است [۴، ۵، ۲۷]:

$$\underline{o}^{j,(t)} = \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}}{\sigma_r^{j,(t)}} \right)^2 \right] = \psi \left[\sum_{r=1}^n \left(\underline{u}_r^{j,(t)} \right)^2 \right] = \psi \left(\underline{d}^{j,(t)} \right) = \exp \left(-\frac{1}{2} \underline{d}^{j,(t)} \right) \quad (47)$$

وجود کران پائین انحراف استاندارد، به ازای «وروودی زام» به تُرون زام لایه پنهان شبکه، یعنی $\underline{v}^{j,(t)}$ ، در مخرج کسر $\frac{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}}{\sigma_r^{j,(t)}}$ سبب بزرگ شدن آن و در نتیجه محاسبه $\underline{u}_r^{j,(t)}$ خواهد شد. با به توان دو رساندن و جمع کردن مقادیر $\underline{u}_r^{j,(t)}$ به ازای تمام ورودی‌های $x_r^{(t)} + n_r^{(t)}$ با ابعاد $r = 1, 2, \dots, n$ در تُرون زام لایه پنهان، مendar مثبت $\underline{d}^{j,(t)}$ به دست می‌آید. هنگامی که $\underline{d}^{j,(t)}$ در ضرب $\frac{1}{2}$ - ضرب واز حاصل ضرب تابع نسایی به صورت $\exp \left(-\frac{1}{2} \underline{d}^{j,(t)} \right) = \frac{1}{\sigma^{(j,(t))}} e^{\left(\frac{-1}{2} \underline{d}^{j,(t)} \right)}$ گرفته می‌شود؛ به دلیل بزرگ شدن مخرج کسر، حاصل تقسیم کوچک شده و کران پائین خروجی تابع گاوسی گرانولی یعنی $\underline{\sigma}^{j,(t)}$ که مقداری مثبت است، به دست می‌آید.

اکنون برای محاسبه کران بالای خروجی یک تابع گاوسی گرانولی خواهیم داشت [۴، ۵، ۲۸]:

$$\overline{o}^{j,(t)} = \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}}{\sigma_r^{j,(t)}} \right)^2 \right] = \psi \left[\sum_{r=1}^n \left(\overline{u}_r^{j,(t)} \right)^2 \right] = \psi \left(\overline{d}^{j,(t)} \right) = \exp \left(-\frac{1}{2} \overline{d}^{j,(t)} \right) \quad (48)$$

وجود کران بالای انحراف استاندارد، به ازای «وروودی زام» به تُرون زام لایه پنهان شبکه، یعنی $\overline{v}^{j,(t)}$ ، در مخرج کسر $\frac{x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)}}{\sigma_r^{j,(t)}}$ سبب کوچک شدن آن و در نتیجه محاسبه $\overline{u}_r^{j,(t)}$ خواهد شد. با به توان دو

پائین و کران بالا در «انحراف استاندارد تابع فعال‌ساز گرانولی» به طور
جداگانه آموزش می‌یابند. پس به جای دو پارامتر، سه پارامتر برای
آموزش وجود دارد [۳۷، ۳۸].

۲-۴ الگوریتم پس انتشار خطای گرانولی^۲

استفاده از گرادیان نزولی^۳

الگوریتم پس انتشار خطای گرانولی برای n ورودی و m خروجی و
بک خروجی، بر اساس روش مجموع مربعات خطای صورت زیر
محاسبه می‌گردد [۴، ۵]

$$e^{(t)} = d^{(t)} - y_N^{(t)}, \quad E^{(t)} = \frac{1}{2} (e^{(t)})^2,$$

$$e^{(t)} = d^{(t)} - \left(\frac{y_N^{(t)}}{2} + \frac{\bar{y}_N^{(t)}}{2} \right) \quad (55)$$

وزن‌های لایه خروجی را به این صورت آموزش می‌دهیم که برای
هر بازه بک «مقدار مرکزی»^۴ و بک «مقدار تغییرات»^۵ که می‌تواند در دو
طرف مقدار مرکزی بکسان باشد^۶ و با بکسان باشد^۷، در نظر می‌گیریم.
پس دو پارامتر در لایه خروجی آموزش می‌یابند که (الف) مرکز وزن‌های
بازمای و (ب) بازه وزن‌ها می‌باشند. برای مرکز وزن‌های لایه خروجی
داریم:

$$\Delta v^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial v^{j,(t)}} \\ = \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial y^{(t)}} \times \frac{\partial y^{(t)}}{\partial v^{j,(t)}} \right) \\ + \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \bar{y}^{(t)}} \times \frac{\partial \bar{y}^{(t)}}{\partial v^{j,(t)}} \right) \quad (56)$$

$$\Delta v^{j,(t)} = \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times \underline{o}^{j,(t)} \right] \\ + \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times \bar{o}^{j,(t)} \right] \quad (57)$$

$$\Delta v^{j,(t)} = \left(\frac{1}{2} \times \eta \times e^{(t)} \times \underline{o}^{j,(t)} \right) + \left(\frac{1}{2} \times \eta \times e^{(t)} \times \bar{o}^{j,(t)} \right) \quad (58)$$

$$v^{j,(t+1)} = v^{j,(t)} + \Delta v^{j,(t)} = v^{j,(t)} + \eta e^{(t)} o^{j,(t)} \quad (59)$$

و برای بازه وزن‌های لایه خروجی داریم:

$$\underline{y}_N^{(t)} = \sum_{j=1}^m (\underline{v}^{j,(t)} \times \underline{o}^{j,(t)}) \\ = \sum_{j=1}^m [(v^{j,(t)} - |s^{j,(t)}|) \times \underline{o}^{j,(t)}] \quad (49)$$

$$\bar{y}_N^{(t)} = \sum_{j=1}^m (\bar{v}^{j,(t)} \times \bar{o}^{j,(t)}) \\ = \sum_{j=1}^m [(v^{j,(t)} + |s^{j,(t)}|) \times \bar{o}^{j,(t)}] \quad (50)$$

در حالت سوم به علت منفی بودن $\underline{v}^{j,(t)}$ و $\bar{v}^{j,(t)}$ و مثبت بودن
 $\underline{o}^{j,(t)}$ و $\bar{o}^{j,(t)}$ محاسبه کران پائین و کران بالای خروجی نهایی شبکه
عصبی RBF گرانولی، به همراه پارامترهای خطی کران پائین و کران
بالای لایه خروجی شبکه به این صورت خواهد بود:

$$\underline{y}_N^{(t)} = \sum_{j=1}^m (\underline{v}^{j,(t)} \times \underline{o}^{j,(t)}) \\ = \sum_{j=1}^m [(v^{j,(t)} - |s^{j,(t)}|) \times \underline{o}^{j,(t)}] \quad (51)$$

$$\bar{y}_N^{(t)} = \sum_{j=1}^m (\bar{v}^{j,(t)} \times \bar{o}^{j,(t)}) \\ = \sum_{j=1}^m [(v^{j,(t)} + |s^{j,(t)}|) \times \bar{o}^{j,(t)}] \quad (52)$$

و خروجی نهایی از میانگین کران پائین و کران بالا از رابطه (52) و با به
به فرم تطبیق‌بندی^۸ از رابطه (53) به دست می‌آید [۶]:

$$y_N^{(t)} = \frac{\underline{y}_N^{(t)} + \bar{y}_N^{(t)}}{2} \quad (53)$$

$$y_N^{(t)} = \alpha_l \times \underline{y}_N^{(t)} + \alpha_u \times \bar{y}_N^{(t)} \quad (54)$$

که در آن α_l و α_u به ترتیب پارامترهای تطبیقی کران پائین و کران
بالای خروجی هستند.

۲-۴ الگوریتم خوشبندی K-Means با m خوش

گام‌های الگوریتم برای آموزش پارامترهای لایه میانی شبکه عصبی
RBF گرانولی، کاملاً مشابه الگوریتم آموزش برای نوع غیربازمای این
شبکه عصبی می‌باشد. تنها تفاوت در این است که در اینجا هر دو کران

² Gramular Error Back Propagation with Steepest Gradient Descent

³ Midpoint

⁴ Interval

⁵ Symmetrical

⁶ Asymmetrical

⁷ Adaptive form

$$\Delta c_r^{j,(t)} = \left[\frac{1}{2} \times \eta \times e^{(t)} \times \frac{\underline{v}^{j,(t)} \times \underline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \right] + \left[\frac{1}{2} \times \eta \times e^{(t)} \times \frac{\overline{v}^{j,(t)} \times \overline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \right] \quad (66)$$

$$\Delta c_r^{j,(t)} = \left[\frac{1}{2} \times \eta \times e^{(t)} \times \frac{\underline{v}^{j,(t)} \times \underline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2 + \overline{v}^{j,(t)} \times \overline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \right] \quad (67)$$

$$c_r^{j,(t+1)} = c_r^{j,(t)} + \Delta c_r^{j,(t)} = c_r^{j,(t)} + \frac{1}{2} \eta e^{(t)} \frac{\underline{v}^{j,(t)} \times \underline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2 + \overline{v}^{j,(t)} \times \overline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \quad (68)$$

برای آموزش کران پائین انحراف استاندارد که از پارامترهای لابه مبانی است با فرض $\overline{d}^{j,(t)} \geq \underline{d}^{j,(t)}$ و $\overline{o}^{j,(t)} \geq \underline{o}^{j,(t)}$ خواهد داشت:

$$\Delta \sigma_r^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial \underline{o}_r^{j,(t)}} = -\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \underline{y}^{(t)}} \times \frac{\partial \underline{y}^{(t)}}{\partial \underline{o}_r^{j,(t)}} \times \frac{\partial \underline{o}_r^{j,(t)}}{\partial \underline{d}^{j,(t)}} \times \frac{\partial \underline{d}^{j,(t)}}{\partial \sigma_r^{j,(t)}} \quad (69)$$

$$\Delta \sigma_r^{j,(t)} = -\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times (v^{j,(t)} - s^{j,(t)}) \times \left(-\frac{1}{2} \times \underline{o}^{j,(t)} \right) \times \left[-2 \times \frac{(\underline{u}_r^{j,(t)})^2}{\sigma_r^{j,(t)}} \right] = \frac{1}{2} \times \eta \times e^{(t)} \times v^{j,(t)} \times \frac{\underline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{\sigma_r^{j,(t)}} \quad (70)$$

$$\underline{\sigma}_r^{j,(t+1)} = \underline{\sigma}_r^{j,(t)} + \Delta \sigma_r^{j,(t)} = \underline{\sigma}_r^{j,(t)} + \frac{1}{2} \eta e^{(t)} v^{j,(t)} \frac{\underline{o}^{j,(t)} \times (\underline{u}_r^{j,(t)})^2}{\sigma_r^{j,(t)}} \quad (71)$$

برای آموزش کران بالای انحراف استاندارد که از پارامترهای لابه مبانی است با فرض $\overline{d}^{j,(t)} \geq \underline{d}^{j,(t)}$ و $\overline{o}^{j,(t)} \geq \underline{o}^{j,(t)}$ خواهد داشت:

$$\Delta \overline{\sigma}_r^{j,(t)} = -\eta \times \frac{\partial E^{(t)}}{\partial \overline{o}_r^{j,(t)}} = -\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \overline{y}^{(t)}} \times \frac{\partial \overline{y}^{(t)}}{\partial \overline{o}_r^{j,(t)}} \times \frac{\partial \overline{o}_r^{j,(t)}}{\partial \overline{d}^{j,(t)}} \times \frac{\partial \overline{d}^{j,(t)}}{\partial \sigma_r^{j,(t)}} \quad (72)$$

$$\begin{aligned} \Delta s^{j,(t)} &= -\eta \times \frac{\partial E^{(t)}}{\partial s^{j,(t)}} \\ &= \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \underline{y}^{(t)}} \times \frac{\partial \underline{y}^{(t)}}{\partial s^{j,(t)}} \right) \\ &\quad + \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \overline{y}^{(t)}} \times \frac{\partial \overline{y}^{(t)}}{\partial s^{j,(t)}} \right) \end{aligned} \quad (73)$$

$$\Delta s^{j,(t)} = \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times \underline{o}^{j,(t)} \right] + \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times \overline{o}^{j,(t)} \right] \quad (74)$$

$$\Delta s^{j,(t)} = \left(\frac{1}{2} \times \eta \times e^{(t)} \times \underline{o}^{j,(t)} \right) + \left(\frac{1}{2} \times \eta \times e^{(t)} \times \overline{o}^{j,(t)} \right) \quad (75)$$

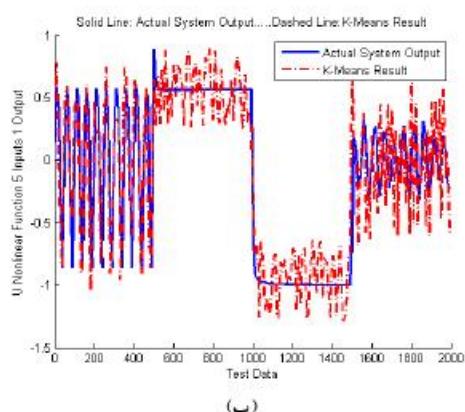
$$s^{j,(t+1)} = s^{j,(t)} + \Delta s^{j,(t)} = s^{j,(t)} + \eta e^{(t)} o^{j,(t)} \quad (76)$$

در لایه میانی سه پارامتر وابسته به تابع فعال ساز گرانولی آموزش می‌بینند که (الف) مرکز دسته، (ب) کران پائین انحراف استاندارد و (ج) کران بالای انحراف استاندارد می‌باشد.

برای آموزش مرکز توابع گاوسی که از پارامترهای لایه میانی است و با فرض $\underline{o}^{j,(t)} \geq \overline{o}^{j,(t)}$ و $\overline{d}^{j,(t)} \geq \underline{d}^{j,(t)}$ خواهیم داشت [۴]:

$$\begin{aligned} \Delta c_r^{j,(t)} &= -\eta \times \frac{\partial E^{(t)}}{\partial c_r^{j,(t)}} \\ &= \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \underline{y}^{(t)}} \times \frac{\partial \underline{y}^{(t)}}{\partial \underline{o}_r^{j,(t)}} \right. \\ &\quad \times \frac{\partial \underline{o}_r^{j,(t)}}{\partial \overline{d}^{j,(t)}} \times \frac{\partial \overline{d}^{j,(t)}}{\partial c_r^{j,(t)}} \Bigg) \\ &\quad + \left(-\eta \times \frac{\partial E^{(t)}}{\partial e^{(t)}} \times \frac{\partial e^{(t)}}{\partial \overline{y}^{(t)}} \times \frac{\partial \overline{y}^{(t)}}{\partial \overline{o}_r^{j,(t)}} \right. \\ &\quad \times \frac{\partial \overline{o}_r^{j,(t)}}{\partial \underline{d}^{j,(t)}} \times \frac{\partial \underline{d}^{j,(t)}}{\partial c_r^{j,(t)}} \Bigg) \end{aligned} \quad (77)$$

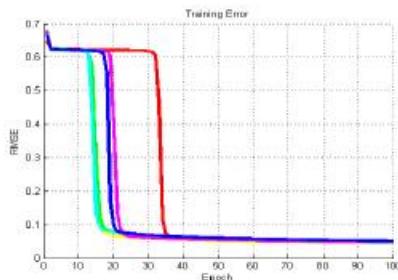
$$\begin{aligned} \Delta c_r^{j,(t)} &= \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times (v^{j,(t)} - s^{j,(t)}) \times \left(-\frac{1}{2} \times \underline{o}^{j,(t)} \right) \right. \\ &\quad \times \left. \left(-2 \times \frac{(\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \right) \right] \\ &\quad + \left[-\eta \times e^{(t)} \times \left(-\frac{1}{2} \right) \times (v^{j,(t)} + s^{j,(t)}) \right. \\ &\quad \times \left. \left(-\frac{1}{2} \times \overline{o}^{j,(t)} \right) \times \left(-2 \times \frac{(\underline{u}_r^{j,(t)})^2}{(x_r^{(t)} + n_r^{(t)} - c_r^{j,(t)})} \right) \right] \end{aligned} \quad (78)$$



(ب)

شکل ۵ شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی، توسط شبکه عصبی RBF گرانولی با ۲۰ کرون لایه میانی و (الف) بدون نویز ب $SNR=0$

در شکل ۶ خطای آموزش شناسایی «سیستم غیر خطی پویای U در شکل با پنج ورودی، برای ۶ بار اجرای برنامه آورده شده است.



شکل ۶ خطای آموزش شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی، توسط شبکه عصبی RBF گرانولی با ۲۰ کرون لایه میانی و $SNR=0$

تعداد داده‌های به کار رفته برای آموزش در این مثال ۱۵۰۰ داده است. در این مسأله ۴۴۲ داده به عنوان داده آزمایشی به کار رفته‌اند.

در جدول ۱ نتایج شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی، توسط شبکه عصبی RBF گرانولی و شبکه عصبی RBF برای ۱۰۰ بار نکرار الگوریتم آورده شده است.

جدول ۱ نتایج شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی، توسط شبکه عصبی RBF گرانولی و شبکه عصبی

RBF	شبکه عصبی		RBF		خطا (RMS)	SNR (دسى بول)
	گرانولی	K-Means	گرانولی	K-Means		
گردیدن نزولی	تعداد نزون های لایه	تعداد نزون های لایه	گردیدن نزولی	تعداد نزون های لایه		
۲۰	۱۰	۲۰	۱۰	۲۰	۱	۱
۰/۱۷۷۵	۰/۱۸۷۶	۰/۰۷۰۰	۰/۰۷۱۲	۰/۰۶۴۹	۰/۰۶۷۷	۰/۰۷۸۲
۰/۰۳۴۵	۰/۰۳۹۲	۰/۰۳۶۵	۰/۰۳۶۷	۰/۰۳۱۰	۰/۰۳۲۲	۰/۰۳۲۴
۰/۱۵۵۵	۰/۱۵۸۴	۰/۰۵۸۸	۰/۰۶۰۵	۰/۰۵۸۰	۰/۰۶۱۶	۰/۰۷۸۱
۰/۰۴۰۰	۰/۰۴۴۱	۰/۰۳۱۵	۰/۰۳۴۲	۰/۰۳۲۶	۰/۰۳۵۳	۰/۰۳۴۶
۰/۰۹۷۵	۰/۱۰۰	۰/۰۵۰۰	۰/۰۵۰۵	۰/۰۵۲۳	۰/۰۵۷۵	۰/۰۲۵۰
۰/۰۲۰۰	۰/۰۰۲۸	۰/۰۰۲۰	۰/۰۰۲۴	۰/۰۰۲۱	۰/۰۰۶۹	۰/۰۲۹۴
۰/۰۴۴۵	۰/۰۴۷۰	۰/۰۴۰۰	۰/۰۴۲۲	۰/۰۴۷۷	۰/۰۴۹۲	۰/۰۲۲۱
۰/۰۵۲۱	۰/۰۵۶۰	۰/۰۵۰۵	۰/۰۵۰۱	۰/۰۵۲۳	۰/۰۵۷۲	۰/۰۳۰۵

همانطور که از نتایج مدرج در جدول ۱ معلوم می‌گردد در شرایطی که داده‌های ورودی آغشته به نویز نیستند، عملکرد شبکه عصبی RBF

$$\Delta \bar{\sigma}_r^{j,(t)} = -\eta \times e^{(t)} \times \left(-\frac{1}{2} \times (v^{j,(t)} + s^{j,(t)}) \times \left(-\frac{1}{2} \times \bar{\sigma}_r^{j,(t)}\right) \times \left(-2 \times \frac{(u_r^{j,(t)})^2}{\bar{\sigma}_r^{j,(t)}}\right)\right) = \frac{1}{2} \times \eta \times e^{(t)} \times \bar{v}^j \times \frac{\bar{\sigma}_r^{j,(t)} \times (u_r^{j,(t)})^2}{\bar{\sigma}_r^{j,(t)}} \quad (73)$$

$$\bar{\sigma}_r^{j,(t+1)} = \bar{\sigma}_r^{j,(t)} + \Delta \bar{\sigma}_r^{j,(t)} = \bar{\sigma}_r^{j,(t)} + \frac{1}{2} \eta e^{(t)} \bar{v}^j \frac{\bar{\sigma}_r^{j,(t)} \times (u_r^{j,(t)})^2}{\bar{\sigma}_r^{j,(t)}} \quad (74)$$

۵- نتایج شبیه‌سازی

۱-۵ شناسایی سیستم غیر خطی پویای U شکل با پنج ورودی

هدف شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی» است که توسط معادلات زیر تولید می‌گردد [۶]

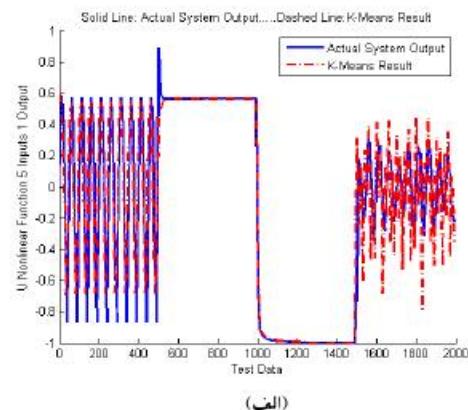
$$y_p(k+1) = f(y_p(k), y_p(k-1), y_p(k-2), u(k), u(k-1)) \quad (75)$$

که در آن:

$$f(x_1, x_2, x_3, x_4, x_5) = \frac{x_1 x_2 x_3 x_5 (x_3-1)+x_4}{1+x_2^2+x_3^2} \quad (76)$$

$$u(k) = \begin{cases} \sin\left(\frac{\pi k}{25}\right) & 0 < k < 500 \\ +1 & 500 \leq k < 1000 \\ -1 & 1000 \leq k < 1500 \\ 0.3 \sin\left(\frac{\pi k}{25}\right) + 0.1 \sin\left(\frac{\pi k}{32}\right) + 0.6 \sin\left(\frac{\pi k}{10}\right) & 1500 \leq k \leq 2000 \end{cases} \quad (77)$$

در شکل ۵، رنگ «آبی» و «منته» نشان دهنده خروجی واقعی سیستم و رنگ «قرمز و خط چین» نشان دهنده شناسایی سیستم به کمک روش الگوریتم خوشبندی K-Means است.



(الف)

پس در شرایطی که داده‌های ورودی آنچه به نویز ضعف و متوسط هستند، نیز شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» هم چنان بهترین عملکرد را دارد ولی پس از آن شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی» و دست آخر شبکه عصبی RBF فرار می‌گیرد.

نتایج موجود در جدول ۱ همچنین نشان می‌دهد که در نویز با نسبت سیگنال به نویز، برابر صفر، عملکرد شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی» بهتر از حالتی است که پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» آموزش می‌بینند. چرا که در هنگام وجود نویز فری در داده ورودی، تعیین تعلق آن به یک خوشه دشوار می‌باشد و خطای بوجود آمده در تعیین خوشه بر تقریب ناشی از محاسبات بازه‌ای غلبه می‌باشد.

پس در وضیعت وجود نویز فری در داده ورودی، شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»، بهترین عملکرد را دارد و پس از آن شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» و دست آخر شبکه عصبی RBF فرار می‌گیرد.

جدول ۲ مقایسه نتایج شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی»، بوسیله شبکه عصبی RBF گرانولی، با شبکه عصبی فازی که آموزش پارامترهای متفاوت و تالی در آن به دو روش «بهینه‌سازی گروهی ذرات عمومی» و «بهینه‌سازی گروهی ذرات بهبود یافته» صورت پذیرفته را نشان می‌دهد.^[۳۶]

جدول ۲. نتایج شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی» توسط شبکه عصبی RBF گرانولی و شبکه‌های عصبی - فازی دیگر

نحوه آموزش	نحوه ایجاد نمونه	نحوه ایجاد نمونه	نحوه ایجاد نمونه	(RMS)	(SNR)
RBF گرانولی ۱۰۰ epochs	شبکه عصبی گرانولی ۴۰ نمونه لایه میانی	شبکه عصبی گرانولی ۲۰ نمونه لایه میانی	شبکه عصبی گرانولی ۱۰ نمونه لایه میانی	۰/۰۴۹۹	۰/۰۴۹۱
K-Means	گرادیان نزولی	K-Means	K-Means	۰/۰۴۷۶	۰/۰۴۱۴
شبکه عصبی - فازی دیگر	آموزش داده همراه با ایجاد نمونه	آموزش داده همراه با ایجاد نمونه	آموزش داده همراه با ایجاد نمونه	۰/۰۴۹۱	۰/۰۴۹۰
شبکه عصبی - فازی دیگر	آموزش داده همراه با ایجاد نمونه	آموزش داده همراه با ایجاد نمونه	آموزش داده همراه با ایجاد نمونه	۰/۰۴۷۶	۰/۰۴۱۴
۰/۰۰۰۲۰	۰/۰۱۷	۰/۰۴۱۴	۰/۰۴۹۱	۰/۰۴۷۶	۰/۰۴۹۰
?	?	۰/۰۴۹۷	۰/۰۴۹۷	۰/۰۴۸۲	۰/۰۴۹۷
بدون نویز	بدون نویز	بدون نویز	بدون نویز	بدون نویز	بدون نویز

گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» نسبت به عملکرد همین شبکه با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی» و شبکه عصبی RBF با آموزش تمام پارامترها بوسیله روش «گرادیان نزولی»، تا حدی بهتر می‌باشد. دلیل این مسأله این است که در شناسایی سیستم‌های غیر خطی بوبا و در شرایطی که داده‌های ورودی آنچه به نویز نیستند، تعیین تعلق بک دسته داده ورودی به یک خوشه به درستی و به سرعت صورت می‌پذیرد. و این تعیین دقیق خوشه در لایه پنهان، مبنای شناسایی درست و سریع در لایه خروجی فرار خواهد گرفت. در حالیکه الگوریتم «گرادیان نزولی» به دلیل احتساب گیر اضافه در مبنیس محلى و دشواری بافت نوخ آموزش مناسب، در تعداد دفعات تکرار مساوی، در شناسایی سیستم‌های غیر خطی بوبا ضعیفتر عمل می‌کند.

در شرایط بدون نویز، برتری جزئی عملکرد شبکه عصبی RBF نسبت به شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»، به دلیل تقریب ناشی از محاسبات بازه‌ای است که روش «گرادیان نزولی» در شبکه عصبی RBF گرانولی را با خطای حاصل از تقریب روپرتو می‌سازد.

پس در شرایط بدون نویز، شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» بهترین عملکرد را دارد و پس از آن شبکه عصبی RBF و در نهایت شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»، فرار می‌گیرد.

در شرایطی که داده‌های ورودی آنچه به نویز ضعف و متوسط هستند نیز برتری روش «الگوریتم خوشبندی K-Means»، البته به مقدار کمتر^۱ از آن می‌باشد. برتری کمتر «الگوریتم خوشبندی K-Means» در حضور نویز به این دلیل است که هر چه دامنه نویز بیشتر می‌گردد؛ تعیین تعلق دسته داده ورودی به یک خوشه مشکلتر می‌شود. ولی خطای بوجود آمده از این مسأله هنوز آن اندازه بزرگ نشده که بر نقاط ضعف الگوریتم «گرادیان نزولی» غلبه نماید.

همچنین مشاهده می‌گردد که هر چه میزان نویز تزریق شده به داده‌ها بیشتر باشد، عملکرد شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»، نسبت به شبکه عصبی RBF بهتر شود. هلت این امر این است که خطای حاصل از تقریب در محاسبات بازه‌ای آندر بزرگ نیست که سردرگمی شبکه عصبی RBF در مقابل داده‌های ورودی آنچه به نویز را جهان کند. در نسخه خطای شناسایی شبکه عصبی RBF، با افزایش دامنه نویز به سرعت بزرگتر می‌گردد و این شبکه عصبی توانایی شناسایی خود را هر چه بیشتر از دست می‌دهد.

² General Particular Swarm Organization (General PSO)

³ Modified Particular Swarm Organization (Modified PSO)

^۱ این مقدار وابسته به دامنه نویز است

دلیل این مسئله این است که در پیش‌بینی توانع آشوب در افق زمانی بزرگ و در شرایطی که داده‌های ورودی آخشنده به نویز نیستند، تعیین تعلق یک دسته داده ورودی به یک خوش در لایه پنهان درست و سرع صورت می‌پذیرد. حال از آن جایی که در بحث پیش‌بینی فرض بر آن است که دو بردار ورودی که فاصله اقلیدسی کمی دارند، خروجی‌های نزدیک به هم تولید کنند تا سیستم پیش‌بینی پذیر گردد. ولی در توانع آشوب در افق زمانی بزرگ، دو بردار ورودی که فاصله اقلیدسی کمی دارند، ممکن است که خروجی‌های دور از هم تولید کنند. پس باید پارامترهای همانند وزن‌های بازه‌ای لایه خروجی^۱، درجه آزادی شبکه عصبی RBF گرانولی را به اندازه‌ای بالا ببرند که به کمک آموزش وزن‌های بازه‌ای لایه خروجی^۲، بتوان این ویژگی توانع آشوب را پوشش داد و تولید خروجی‌های دور از هم را پیش‌بینی نمود. در نهایت در نزد نفاط صعف روش «گرادیان نزولی»^۳ یعنی اختلال گیر افتادن در مینیمم محلی و دشواری یافتن نرخ آموزش مناسب، برتری در شرایط فاقد نویز با روش الگوریتم خوشبندی K-Means^۴ خواهد بود.

سرانجام در شبکه عصبی RBF به علت بازه‌ای نبودن وزن‌های لایه خروجی^۱، انعطاف‌پذیری شبکه عصبی برای پیش‌بینی تولید خروجی‌های دور از هم در توانع آشوب، کسر شده و همین مسئله وجود خطای ناشی از تغییر در محاسبات بازه‌ای در شبکه عصبی RBF گرانولی را پوشش داده و دو شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»، و شبکه عصبی RBF با آموزش تمام پارامترها بوسیله روش «گرادیان نزولی» را به نتایج مشابهی می‌رساند. در حالی که شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means»^۴ به علت رهایی از روش «گرادیان نزولی» در آموزش پارامترهای لایه پنهان، به نتایج بهتری دست یافدم کنم.

پس در شرایط بدون نویز، شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means» بهترین عملکرد را دارد و پس از آن شبکه عصبی RBF و شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی» در یک رده قرار می‌گیرند.

علت برتری روش «گرادیان نزولی» در شبکه عصبی RBF گرانولی^۱، و در هنگام شناسایی و پیش‌بینی توانع آشوب در افق زمانی بزرگ^۲، به نویز در حضور نویز با «نسبت سیگنال به نویز»^۳ برابر صفر و پنج و تا حدۀ کمتری^۴، این است که چون در آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means»، و با حضور نویز متسط و قوی و تا حدۀ نویز ضعیف، تعیین تعلق دسته داده ورودی به یک خوش به درستی و به سرعت صورت نگرفته است، پس آموزش وزن‌های بازه‌ای لایه خروجی در شناسایی و پیش‌بینی درست توانع آشوب کارساز نیست

خطای آزمون برای این شبکه عصبی فازی در دسترس نبود. ولی از مقایسه خطای آموزش می‌توان بی برد که روند شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی، بوسیله شبکه عصبی RBF گرانولی»^۱ مارغ از نوع آموزش پارامترهای آن، نسبت به شبکه عصبی فازی با آموزش پارامترهای مقدم و تالی به روش «بهیه‌سازی گروهی ذرات عمومی»^۲ بهتر صورت می‌پذیرد.

هر چند که در ۱۰۰ بار تکرار الگوریتم، شبکه عصبی فازی با آموزش پارامترهای مقدم و تالی به روش «بهیه‌سازی گروهی ذرات» بهبود یافته، توانایی بیشتری را در شناسایی «سیستم غیر خطی پویای U شکل با پنج ورودی» نشان می‌دهد. ولی به علت زیاد بودن تعداد پارامترها و کندی الگوریتم‌های نکاملی از جمله الگوریتم نکاملی «بهیه‌سازی گروهی ذرات» بهبود یافته، به نظر می‌رسد که این الگوریتم‌ها باید زمان اجرای بزرگتر داشته باشد.

۲-۵ پیش‌بینی سری زمانی مکی گلاس با توجه به وجود نویز ورودی

این سری زمانی توسط معادله زیر تولید می‌گردد^[۳۰]:

$$\dot{x} = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (78)$$

از ۱۲۰۱ داده تولید شده به وسیله این سری زمانی^۱ تعداد ۸۴۰ داده به عنوان داده آموزشی^۲ و ۳۵۲ تا به عنوان داده آزمایشی^۳ به کار رفته‌اند.

جدول ۲- نتایج پیش‌بینی سری زمانی مکی گلاس توسط شبکه عصبی RBF گرانولی و شبکه عصبی RBF

RBF	شبکه عصبی RBF گرانولی	شبکه عصبی RBF گرانولی				خطا (RMSE) (دستی) (پل)	SNR (دستی) (پل)
		گرادیان نزولی	K-Means	تعداد نمونه‌های لایه	تعداد نمونه‌های لایه پنهان		
۲۰	۱۰	۲۰	۱۰	۲۰	۱۰	۱	۰
-۰.۱۰۸۶	-۰.۱۱۳۲	-۰.۰۴۰۰	-۰.۰۴۵۲	-۰.۰۲۷۰	-۰.۰۲۲۸	-۰.۵۳۲	۰
-۰.۸۴۳۶	-۰.۹۲۲۵	-۰.۲۲۳۶	-۰.۲۴۰۸	-۰.۲۱۰۷	-۰.۲۰۹۰	-۰.۲۱۱۱	۵
-۰.۰۵۴۵	-۰.۰۵۶۶	-۰.۰۳۱۵	-۰.۰۴۲۵	-۰.۰۱۵۷	-۰.۰۲۰۶	-۰.۲۸۲	۱۰
-۰.۲۰۵۷	-۰.۲۴۷۴	-۰.۲۲۷۵	-۰.۲۴۰۰	-۰.۱۱۷۰	-۰.۱۱۹۰	-۰.۱۱۸۳	۰
-۰.۰۲۰۴	-۰.۰۲۱۷	-۰.۰۲۷۵	-۰.۰۲۹۲	-۰.۰۱۲۸	-۰.۰۱۸۳	-۰.۰۲۴۵	۰
-۰.۱۰۰۳	-۰.۱۱۲۸	-۰.۰۷۸۰	-۰.۰۹۹۵	-۰.۰۶۶۲	-۰.۰۶۶۸	-۰.۰۶۹۱	۰
-۰.۰۱۱۰	-۰.۰۱۱۳	-۰.۰۱۱۱	-۰.۰۱۱۱	-۰.۰۱۱۲	-۰.۰۱۱۳	-۰.۰۲۱۰	بدون آموزش
-۰.۰۱۲۷	-۰.۰۱۳۷	-۰.۰۱۲۷	-۰.۰۱۳۱	-۰.۰۱۲۸	-۰.۰۱۲۷	-۰.۰۲۲۴	نویز آموزن

همانطور که از نتایج مرتب در جدول ۲ معلوم می‌گردد^۴ در شرایطی که داده‌های ورودی آخشنده به نویز نیستند، عملکرد شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه میانی بوسیله روش «الگوریتم خوشبندی K-Means»^۱ نسبت به عملکرد همین شبکه با آموزش پارامترهای لایه میانی بوسیله روش «گرادیان نزولی»^۲، و شبکه عصبی RBF با آموزش تمام پارامترها بوسیله روش «گرادیان نزولی»^۳، اندکی بهتر می‌باشد.

¹ Training data set

² Test data set

در جدول ۴ مقایسه خطای آزمون پیش‌بینی «سری زمانی مکنی»-
گلاس^{۲۰}، توسط «شبکه عصبی RBF گرانولی» با «سیستم‌های منطق فازی
نوع ۱ و نوع ۲»^[۱۱] آورده شده است.

جدول ۴. نتایج پیش‌بینی سری زمانی مکنی گلاس توسط شبکه عصبی
گرانولی و سیستم‌های منطق فازی نوع ۱ و نوع ۲

سیستم‌های منطق فازی	(RMS) (%)		SNR
	K-Means	RBF گرانولی	
۱۵۱۷	۰/۱۴۳۲	۰/۱۴۲۹	۰
۰/۱۵۱۴	۰/۱۴۲۶	۰/۱۴۲۷	۰
۰/۱۵۱۴	۰/۱۴۲۶	۰/۱۴۲۷	۰

همان طور که از مقایسه نتایج متدرج در جدول ۴ مشخص است، در حضور نویز صعب علکرد «شبکه عصبی RBF گرانولی» با هر دو روش آموزش، بهتر از «سیستم‌های منطق فازی نوع ۱ و نوع ۲»^{۲۱} می‌باشد. که با توجه به بیشتر بودن تعداد پارامترهای آموزش دیده در «سیستم‌های منطق فازی نوع ۱ و نوع ۲»، نسبت به «شبکه عصبی RBF گرانولی»، و پیچیدگی بیشتر الگوریتم آموزشی آنها، زمان اجرای برنامه در «سیستم‌های منطق فازی نوع ۱ و نوع ۲» به شدت افزایش می‌باید. و این موضوع برتری «شبکه عصبی RBF گرانولی» را برجسته‌تر می‌سازد.

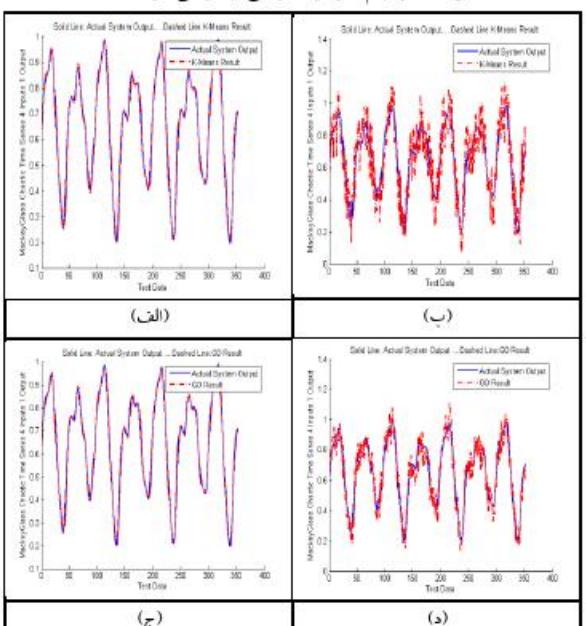
در حضور نویز قوی، علکرد «شبکه عصبی RBF گرانولی» با افزایش تعداد ترُون‌های لایه مبانی^{۲۰} می‌تواند نسبت به علکرد «سیستم‌های منطق فازی نوع ۱ و نوع ۲»، برتری باید. زیرا با افزایش تعداد ترُون‌های لایه مبانی، درجه آزادی سیستم با افزایش تعداد پارامترهای آموزش دیده، زیاد می‌گردد. به عنوان مثال با داشتن ۳۰۰ ترُون در لایه پنهان، خطای آزمون برای روش «الگوریتم خوشبندی K-Means»، به ۰/۱۵ کاهش می‌باید که از «سیستم‌های منطق فازی نوع ۱» بهتر است. البته زمان اجرای برنامه به مقدار زیادی افزایش می‌باید ولی در مقایسه با با زمان اجرای چند دقیقه‌ای «سیستم‌های منطق فازی نوع ۲»، زمان اجرای کمتر از یک دقیقه (جدول ۷) در شبکه عصبی RBF گرانولی^{۲۱}، مناسب به نظر می‌رسد.

و زمان کافی برای آموزش این وزن‌ها در تعداد تکرار محدود الگوریتم وجود ندارد. از این‌رو می‌توان گفت که خطای بوجود آمده در تعیین خوشبندی در «الگوریتم خوشبندی K-Means»، آنقدر بزرگ است که بر خطای تغیر ناشی از محاسبات بازه‌ای، در «الگوریتم گرادیان نزولی» برتری می‌باید و روش «گرادیان نزولی» بهتر عمل می‌نماید.

سراجام در مورد شبکه عصبی RBF می‌توان گفت که در مقابل داده‌های ورودی آنلاین به نویز، دچار سردرگمی در شناسایی و پیش‌بینی توابع آشوب می‌گردد. زیرا به علت گرانولی بودن توابع فعال ساز در لایه پنهان و بازه‌ای نبودن وزن‌های لایه خروجی، انعطاف پذیری کافی در مواجهه با نویز را ندارد.

پس در وضعیت وجود نویز در داده ورودی، شبکه عصبی گرانولی با آموزش پارامترهای لایه مبانی بوسیله روش «گرادیان نزولی» بهترین عملکرد را دارد و پس از آن شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه مبانی بوسیله روش «الگوریتم خوشبندی K-Means»، و دست آخر شبکه عصبی RBF غفار می‌گیرد.

در شکل ۷ رنگ «آبی و متن»، نشان دهنده خروجی واقعی سیستم و رنگ «قرمز و خط چین»، نشان دهنده پیش‌بینی سری زمانی مکنی گلاس توسط شبکه عصبی RBF گرانولی به کمک «الگوریتم خوشبندی K-Means» و «الگوریتم گرادیان نزولی» است. همانطور که انتظار می‌رود در وضعیت عدم وجود نویز در داده ورودی، «الگوریتم خوشبندی K-Means» عملکرد بهتری دارد در حالی که در حضور نویز قوی در داده ورودی، عملکرد «الگوریتم گرادیان نزولی» بهتر می‌گردد.

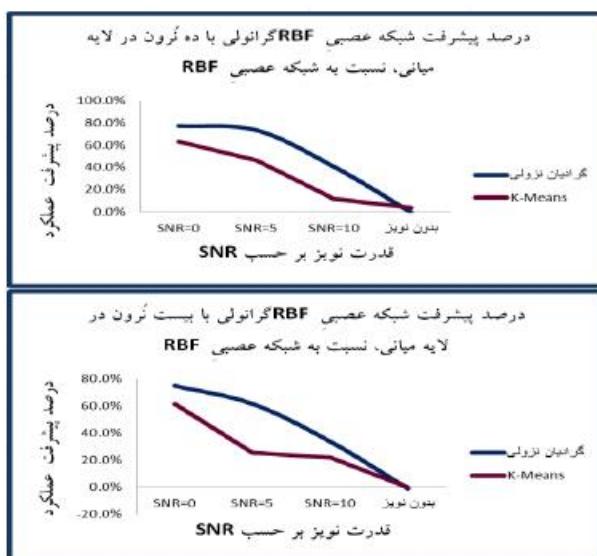


شکل ۷. پیش‌بینی سری زمانی مکنی گلاس توسط شبکه عصبی RBF گرانولی با ترُون لایه مبانی و به روش (الف)، «الگوریتم خوشبندی K-Means» و بدون نویز (ب)، «الگوریتم خوشبندی K-Means» و SNR=۰، (ج) «الگوریتم گرادیان نزولی» و بدون نویز (د) «الگوریتم گرادیان نزولی» و SNR=۰

جدول ۶ درصد بهبود عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF در پیش‌بینی سری زمانی آشوب مکی گلاس

SNR (دستی بیل)	خطای آزمون (بیست نمونه میانی)		خطای آزمون (بیست نمونه لایه میانی)		SNR (دستی بیل)
	شبکه عصبی RBF	گرادیان نزولی	شبکه عصبی RBF	گرادیان نزولی	
بدون نویز	K-Means	گرادیان نزولی	RBF	گرادیان نزولی	بدون نویز
۰/۰۲۲۵	۰/۰۲۴۰۸	۲۱۰۶	۰/۰۲۴۳۶	۲۱۰۷	۰
۰/۰۴۷۴	۰/۰۴۴۰۰	۱۱۹۰	۰/۰۴۰۵۷	۱۱۷۰	۵
۰/۰۱۱۲۸	۰/۰۰۹۹۵	۰/۰۶۶۸	۰/۰۰۷۸۰	۰/۰۶۶۲	۱۰
۰/۰۱۳۲	۰/۰۱۲۳۱	۰/۰۱۲۷	۰/۰۱۲۷	۰/۰۱۲۸	بدون نویز
درصد بهبود					
بدون نویز	K-Means	گرادیان نزولی	RBF	گرادیان نزولی	بدون نویز
۰/۰۴۶۴	۰/۰۴۶۱۱	۷۷/۱	۰/۰۴۱۶	۷۸/۰	۰
۰/۰۱۱۱۸	۰/۰۱۱۱۸	۴۰/۸	۰/۰۲۲۹	۶۱/۷	۵
۰/۰۴۶۴	۰/۰۴۶۴	۷۲/۴	۰/۰۲۵۶	۷۶/۱	۱۰

در شکل ۸ که مربوط به پیش‌بینی «سری زمانی آشوب مکی گلاس» می‌باشد، نمودار کاهش درصد پیشرفت عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی K-Means در هنگام کاهش میزان نویز تزريق شده به داده‌های ورودی و برای هر دو روش آموزشی نشان داده شده است.



شکل ۸ عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF

در جدول ۵ مقایسه خطای آموزش پیش‌بینی «سری زمانی مکی گلاس»، توسط «شبکه عصبی RBF گرانولی» با «شبکه عصبی RBF» فوی با هرس و رشد نرون‌های لایه میانی [۱۶] آورده شده است.

جدول ۵ نتایج پیش‌بینی سری زمانی مکی گلاس توسط شبکه عصبی گرانولی و شبکه عصبی RBF فوی با هرس و رشد نرون‌های لایه میانی

خطای (RMSE)		SNR		(بهترین نتیجه)
شبکه عصبی گرانولی (۱۰۰ epochs)	شبکه عصبی RBF (۱۰۰ epochs)	شبکه عصبی گرانولی (۱۰۰ epochs)	شبکه عصبی RBF (۱۰۰ epochs)	
آموزش	آموزش	آموزش	آموزش	۵ > ۷۴۰
۰/۰۲۰۶	۰/۰۴۷۲۸۵	۰/۰۳۱۵	۰/۰۱۵۷	۰/۰۳۴۵

خطای آزمون برای این شبکه عصبی موجود نبود ولی از مقایسه خطای آموزش می‌توان بی برد که روند پیش‌بینی «سری زمانی مکی گلاس»، بوسیله شبکه عصبی RBF گرانولی فارغ از نوع آموزش یارانترهای آن، نسبت به «شبکه عصبی RBF» فوی با هرس و رشد نرون‌های لایه میانی، بهتر صورت می‌پذیرد. و این برتری با فوایر شدن نویز، نمود پیشرتی می‌باشد. علت این امر وجود تابع فعال ساز گرانولی در ساختار شبکه عصبی گرانولی است که با تنظیم «بارانترهای مریبوط به پهنهای عدم قطعیت»، یعنی کران پایین و کران بالای انحراف اسانسداره، مدبیرت عدم قطعیت در شبکه عصبی RBF گرانولی را انجام می‌دهد.

در جدول ۶ درصد پیشرفت عملکرد شبکه عصبی گرانولی نسبت به شبکه عصبی RBF در هنگام کاهش میزان نویز تزريق شده به داده‌ها آورده شده است. در شبکه عصبی گرانولی، هر دو روش «گرادیان نزولی» و «الگوریتم خوشه‌بندی K-Means»، برای آموزش یارانترهای لایه میانی مدنظر فرار گرفته است. خطای آزمون مربوط به پیش‌بینی «سری زمانی آشوب مکی گلاس»، می‌باشد و در تابع آشوب دبگر مانند «شناشایی جاذب لورنزا» [۳۲] و «شناشایی نگاشت آشوب‌گونه ایکدا» و «شناشایی نگاشت هنون» [۳۱]، نیز انتظار این است که همین رفتار مشاهده گردد [۳۲-۳۷].

^۱ Lorenz attractor

^۲ Daisaku Ikeda

^۳ Hénon map

مقابل نویز، قری^۳ می‌گردد. این مقاله بدان سبب است که تابع فعال‌ساز گرانولی در ساختار شبکه عصبی RBF، با تنظیم «پارامترهای مربوط به بهنای عدم قطعیت»^۴ یعنی کران پائین و کران بالای انحراف استاندارد، باعت کاهش حسابت به تغیرات ورودی می‌شود. بنابراین توصیه می‌گردد که اگر نویز زیادی در داده‌ها وجود دارد با توجه به بهتر بودن عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF از شبکه عصبی RBF گرانولی استفاده شود. اما اگر نویز موجود، مقدار قابل توجهی نداشته باشد، با توجه به سادگی ساختار شبکه عصبی RBF از این ساختار استفاده گردد. سادگی ساختار شبکه عصبی RBF که به دلیل رهایی از محاسبات بازارهای در لایه‌های مبانی و خروجی می‌باشد، سبب کم شدن خطای ناشی از این محاسبات و هم‌چنین کاهش حجم محاسباتی برنامه می‌گردد. کم شدن مقدار تقریب در محاسبه خروجی، می‌تواند در شرایط بدون نویز و به ویژه در شناسابی سیستم‌های غیر خطی پویا، منجر به اندکی بهبود در نتایج گردد.

از طرفی نتایج به دست آمده از شبکه عصبی RBF گرانولی، در شرایطی که داده‌های ورودی آغشته به نویز قری نیستند، نشان دهنده این است که عملکرد «الگوریتم خوشبندی K-Means» در شناسابی سیستم‌های غیر خطی پویا که آشوبی نیستد بهتر است. البته برای شناسابی و پیش‌بینی تولید آشوب برای افق زمانی بزرگ، نتایج به دست آمده بیانگر آن است که عملکرد شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه مبانی بوسیله «الگوریتم گرادیان نزولی» عملکرد بهتری دارد. هر چند که «الگوریتم خوشبندی K-Means» نیز در این شرایط با کیفیت پایین‌تری کاربرد دارد.

با افزایش قدرت نویز در داده‌های ورودی برتری «الگوریتم گرادیان نزولی» به تدریج افزایش می‌باشد تا جایی که در نویز با «نسبت سیگنال به نویز» برابر صفر، عملکرد شبکه عصبی RBF گرانولی با آموزش پارامترهای لایه مبانی بوسیله روش «گرادیان نزولی»^۵ برای شناسابی سیستم‌های غیر خطی پویا و شناسابی و پیش‌بینی تولید آشوب، بهتر از حالتی است که پارامترهای لایه مبانی بوسیله روش «الگوریتم خوشبندی K-Means» آموزش می‌یابند. چرا که در هنگام وجود نویز قری در داده ورودی، تعیین تعلق آن به یک خوشه دشوار می‌باشد و خطای بوجود آمده در تعیین خوشه بر تقریب ناشی از محاسبات بازارهای غلبه می‌باشد.

با این وجود، زمان اجرای برنامه با آموزش پارامترهای لایه مبانی بوسیله «الگوریتم خوشبندی K-Means»، کمتر از روش گرادیان نزولی است. ولت آن این است که مرتبه پیچیدگی الگوریتم و حجم محاسباتی برنامه کاهش یافته و همگرایی پارامترها سریع تر صورت می‌پذیرد. از این‌رو در شرایطی که داده‌های ورودی آغشته به نویز قری نیستند^۶ در تعداد مرحله مساوی، نسبت به روش «گرادیان نزولی»^۷ به جواب بهتری خواهیم رسید.

۳-۵ عوامل مؤثر بر زمان اجرای^۸ برنامه

همانطور که از نتایج به دست آمده از شناسابی «سیستم غیر خطی پویای U شکل با پیچ ورودی» و پیش‌بینی «سری زمانی مکی گلاس»^۹ بی‌دادست، روش «گرادیان نزولی» در حذف اثر نویز با دامنه بالا^{۱۰} در بیشتر موارد نسبت به روش «الگوریتم خوشبندی K-Means»، بهتر عمل می‌کند. البته این بهتر بودن به قیمت حجم بالای محاسباتی که منجر به افزایش زمان اجرای برنامه می‌گردد به دست آمده است.

زمان اجرای برنامه، وابسته به (الف) تعداد پارامترهای انتخاب شده برای آموزش (ب) حجم محاسبات (ج) برخی و بیزگی‌های روش آموزش مانند پیچیدگی الگوریتم آن^{۱۱} می‌باشد. به عنوان مثال با افزایش تعداد ترکونهای لایه پنهان، تعداد پارامترهای انتخاب شده برای آموزش و در نتیجه زمان اجرای برنامه بیشتر می‌گردد. همچنین محاسبات بازارهای در لایه پنهان و لایه خروجی به شدت بر حجم محاسبات می‌افزاید. این قابل محاسبات در روش «گرادیان نزولی» حضور پر رنگتر دارد. و با به دلیل کمتر بودن پیچیدگی «الگوریتم خوشبندی K-Means» نسبت به «گرادیان نزولی»، آموزش شبکه به کمک این الگوریتم، زمان اجرای کمتری دارد. در جدول ۷ نسبت زمان اجرای برنامه با روش «الگوریتم خوشبندی K-Means» به زمان اجرای برنامه با روش «گرادیان نزولی»، برای تعداد متفاوتی از ترکونهای لایه پنهان آورده شده است.

جدول ۷. نسبت زمان اجرای برنامه با روش «الگوریتم خوشبندی K-Means» به زمان اجرای برنامه با روش «گرادیان نزولی» (زمان‌ها بر حسب ثانیه است)

قعداد ترکونهای لایه پنهان	سیستم غیر خطی پویای U سرقی مکی گلاس	سیستم غیر خطی پویای U شکل با پیچ ورودی
۲۰۰	$\frac{30}{73.4} = 0.41$	$\frac{41.6}{120.1} = 0.35$
۲۰	$\frac{11.5}{26.7} = 0.43$	$\frac{14.2}{37.5} = 0.38$
۱۰	$\frac{10}{22.5} = 0.44$	$\frac{13.1}{33.4} = 0.39$

۶- نتیجه‌گیری

همانطور که از نتایج معلوم می‌گردد صرفنظر از روش آموزش، عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF در شرایطی که داده‌های ورودی آغشته به نویز هستند بهتر می‌باشد. همچنین مشاهده می‌گردد که هر چه میزان نویز تقریب شده به داده‌ها بیشتر باشد در صد بهبود عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF افزایش می‌یابد. به عبارت دیگر بازارهای بودن پارامترها سیستم را در

³ Robust

⁴ The parameters responsible for the width of uncertainty

⁵ Run time

⁶ High Amplitude

همان طور که در محاسبه خروجی نهایی شبکه عصبی RBF گرانولی دیدیم، برای محاسبه خروجی نهایی این شبکه با یک نرون هم چهار حالت زیر را خواهیم داشت.

- حالت اول: اگر $0 > v^{(t)} \text{ و } |s^{(t)}| > v^{(t)}$ باشد آن‌گاه $v^{(t)} > 0$ خواهد بود.
- حالت دوم: اگر $0 < v^{(t)} < |s^{(t)}| \text{ و } v^{(t)} > 0$ باشد آن‌گاه $v^{(t)} < 0$ خواهد بود.
- حالت سوم: اگر $0 < v^{(t)} < |s^{(t)}| \text{ و } |v^{(t)}| > |s^{(t)}|$ باشد آن‌گاه $v^{(t)} < 0$ خواهد بود.
- حالت چهارم: اگر $0 < v^{(t)} < |s^{(t)}| \text{ و } |v^{(t)}| < |s^{(t)}|$ باشد آن‌گاه $v^{(t)} < 0$ خواهد بود.

در حالت‌های اول، دوم و چهارم، کران پایین و کران بالای خروجی نهایی شبکه عصبی RBF گرانولی با یک نرون، به همراه پارامترهای خطی کران پایین و کران بالای لایه خروجی شبکه به این صورت خواهد بود:

$$y_N^{(t)} = v^{(t)} \times o^{(t)} = (v^{(t)} - |s^{(t)}|) \times o^{(t)} \quad (81)$$

$$\bar{y}_N^{(t)} = \bar{v}^{(t)} \times \bar{o}^{(t)} = (v^{(t)} + |s^{(t)}|) \times \bar{o}^{(t)} \quad (82)$$

در حالت سوم به علت منفی بودن $v^{(t)}$ و $\bar{v}^{(t)}$ و مثبت بودن $o^{(t)}$ و $\bar{o}^{(t)}$ ، محاسبه کران پایین و کران بالای خروجی نهایی شبکه عصبی RBF گرانولی با یک نرون، به صورت پارامترهای خطی کران پایین و کران بالای لایه خروجی شبکه به این صورت خواهد بود:

$$y_N^{(t)} = v^{(t)} \times o^{(t)} = (v^{(t)} - |s^{(t)}|) \times o^{(t)} \quad (83)$$

$$\bar{y}_N^{(t)} = \bar{v}^{(t)} \times \bar{o}^{(t)} = (v^{(t)} + |s^{(t)}|) \times \bar{o}^{(t)} \quad (84)$$

و خروجی نهایی از مبانگین کران پایین و کران بالا به دست می‌آید:

$$y_N^{(t)} = \frac{y_N^{(t)} + \bar{y}_N^{(t)}}{2} \quad (85)$$

اکنون با سه فرض زیر اثبات را ارائه می‌کنیم:

- وزن لایه خروجی، یعنی $v^{(t)}$ بازه‌ای بوده و مساوی یک باشد، در آن صورت خواهیم داشت:

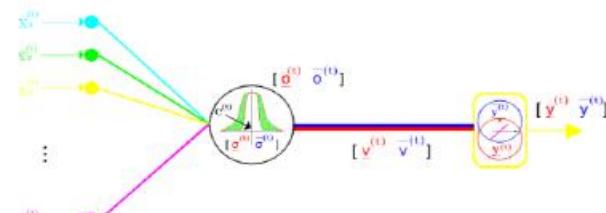
$$\begin{aligned} y_N^{(t)} &= \frac{y_N^{(t)} + \bar{y}_N^{(t)}}{2} = \frac{(\bar{v}^{(t)} \times o^{(t)}) + (v^{(t)} \times \bar{o}^{(t)})}{2} = \\ &\underline{\underline{o^{(t)} + \bar{o}^{(t)}}} = \\ &\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] + \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] \end{aligned} \quad (86)$$

- هم‌چنین مقدار اولیه مرکز تابع فعال‌ساز گاوسی نرون لایه پنهان بعنی c مساوی صفر در نظر گرفته می‌شود.

۷- پیوست: اثبات بهبود یافتن عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی در شرایط نویزی

۱-۷ اثبات برای حالتی که یک نرون در لایه میانی وجود داشته باشد

برای اثبات بهبود یافتن عملکرد شبکه عصبی RBF گرانولی نسبت به شبکه عصبی RBF در شرایط نویزی، از یک شبکه عصبی گرانولی با یک نرون در لایه میانی استفاده می‌کنیم. اثبات می‌گردد که هر چه میزان نویز تزریق شده به داده‌ها بیشتر باشد، شبکه عصبی گرانولی با افزایش «afasle» کران پائین انحراف استاندارد از کران بالای آن، و در نتیجه افزایش «بهنای عدم قطعیت» و با همان تابع فعال‌ساز گاوسی گرانولی، اثر نویز در خروجی شبکه را مهار می‌نماید. هم‌چنین هر چه میزان نویز تزریق شده به داده‌ها کمتر باشد ساختار شبکه عصبی RBF گرانولی به شبکه عصبی RBF نزدیکتر می‌شود تا در شرایط بدون نویز دو ساختار مشابه بکدیگر می‌گردند. البته این تغییر ساختار ناشی از بازه‌ای بودن دو پارامتر است، یعنی «انحراف استاندارد تابع فعال‌ساز گرانولی» در لایه میانی، و دیگری «وزن‌های بازه‌ای» در لایه خروجی می‌باشد.



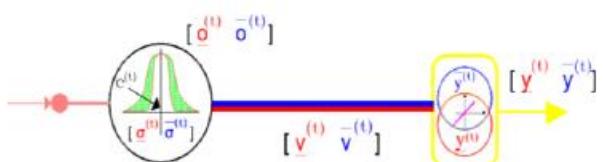
شکل ۹. یک شبکه عصبی RBF گرانولی با یک نرون در لایه میانی محاسبه کران پائین خروجی یک تابع گاوسی گرانولی در لایه میانی به شکل زیر است:

$$\begin{aligned} o^{(t)} &= \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] = \\ &\psi \left[\sum_{r=1}^n \left(\frac{\underline{v}^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] = \exp \left(-\frac{1}{2} \underline{d}^{(t)} \right) \quad (79) \end{aligned}$$

اکنون برای محاسبه کران بالای خروجی یک تابع گاوسی گرانولی در لایه میانی خواهیم داشت:

$$\begin{aligned} \bar{o}^{(t)} &= \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)} - c_r^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] = \\ &\psi \left[\sum_{r=1}^n \left(\frac{\bar{v}^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] = \exp \left(-\frac{1}{2} \bar{d}^{(t)} \right) \quad (80) \end{aligned}$$

اکنون برای کاهش تعداد متغیرها در تابع خروجی در وضعت بدون نویز و نویزی، با فرض این که ابعاد بردار ورودی برابر بک باشد بعضی اثبات را ادامه می‌دهیم:



شکل ۱۱. یک شبکه عصبی RBF گرانولی با یک ترون در لایه میانی و بردار یک بعدی ورودی

در این صورت خواهیم داشت:

$$y^{(t)} = f(x^{(t)}) = \frac{1}{2} \times \psi \left[(x^{(t)})^2 \right] + \frac{1}{2} \times \psi \left[\frac{(x^{(t)})^2}{(1+\sigma^{(t)})^2} \right] \quad (41)$$

$$y_N^{(t)} = f(x^{(t)}, n^{(t)}) = \frac{1}{2} \times \psi \left[(x^{(t)} + n^{(t)})^2 \right] + \frac{1}{2} \times \psi \left[\frac{(x^{(t)} + n^{(t)})^2}{(1+\sigma^{(t)})^2} \right] \quad (42)$$

تفاضل این دو تابع، تابعی است که اختلال ایجاد شده بوسیله نویز^۱ را نشان می‌دهد و عبارت است از:

$$\begin{aligned} DCN &= |y_N^{(t)} - y^{(t)}| \\ &= \frac{1}{2} \\ &\times \left| \psi \left[(x^{(t)} + n^{(t)})^2 \right] \right. \\ &\quad \left. + \psi \left[\frac{(x^{(t)} + n^{(t)})^2}{(1+\sigma^{(t)})^2} \right] \right. \\ &\quad \left. - \psi \left[(x^{(t)})^2 \right] - \psi \left[\frac{(x^{(t)})^2}{(1+\sigma^{(t)})^2} \right] \right| \end{aligned} \quad (43)$$

$$\begin{aligned} DCN &= \frac{1}{2} \times \left| \exp \left[\frac{-(x^{(t)} + n^{(t)})^2}{2} \right] \right. \\ &\quad \left. + \exp \left[\frac{-(x^{(t)} + n^{(t)})^2}{2(1+\sigma^{(t)})^2} \right] \right. \\ &\quad \left. - \exp \left[\frac{-(x^{(t)})^2}{2} \right] \right. \\ &\quad \left. - \exp \left[\frac{-(x^{(t)})^2}{2(1+\sigma^{(t)})^2} \right] \right| \end{aligned} \quad (44)$$

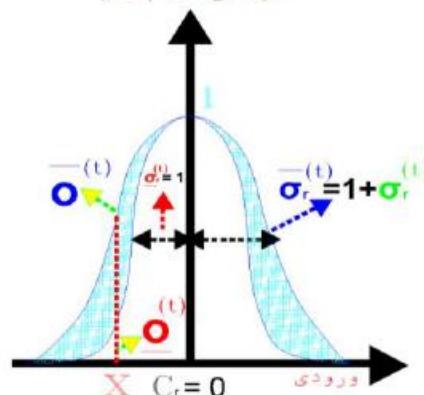
همان‌طور که در بخش ۲ گفته شد، تابع توزیع احتمال گاوسی با نرمال^۲ بر اساس قضیه حد مرکزی از اهمیت زیادی برخوردار است. اکنون «تابع توزیع احتمال» برای نویز ورودی را که به آن «تابع توزیع

$$y_N^{(t)} = \frac{\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)}}{\sigma_r^{(t)}} \right)^2 \right] + \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)}}{1+\sigma_r^{(t)}} \right)^2 \right]}{2} \quad (45)$$

کران پائین انحراف استاندارد مساوی بک $\sigma_r^{(t)} = 1$ و
کران بالای انحراف استاندارد به صورت $\overline{\sigma}_r^{(t)} = 1 + \sigma_r^{(t)}$ در نظر گرفته می‌شود که $\sigma_r^{(t)} = [0 \quad 3]$ بازه تغییرات انحراف استاندارد با گام ۱٪ خواهد بود.

$$\begin{aligned} y_N^{(t)} &= \frac{\psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)}}{1} \right)^2 \right] + \psi \left[\sum_{r=1}^n \left(\frac{x_r^{(t)} + n_r^{(t)}}{1+\sigma_r^{(t)}} \right)^2 \right]}{2} = \frac{1}{2} \times \\ &\psi \left[\sum_{r=1}^n \left(x_r^{(t)} + n_r^{(t)} \right)^2 \right] + \frac{1}{2} \times \psi \left[\sum_{r=1}^n \frac{\left(x_r^{(t)} + n_r^{(t)} \right)^2}{\left(1 + \sigma_r^{(t)} \right)^2} \right] \end{aligned} \quad (46)$$

خروجی لایه پنهان



شکل ۱۰. تابع فعال‌ساز گاوسی گرانولی در ترون لایه میانی و پیش از آغاز آموزش مرکز تابع فعال‌ساز

سبس خروجی شبکه بدون افزودن نویز ورودی و با فرضیات بالا و در نظر گرفتن بردار X به عنوان متغیر مستقل به شکل زیر به دست می‌آید:

$$\begin{aligned} y^{(t)} &= f_{(t)}(X) = f(x_1^{(t)}, x_2^{(t)}, x_3^{(t)}, \dots, x_n^{(t)}) \\ &= \frac{1}{2} \times \psi \left[\sum_{r=1}^n \left(x_r^{(t)} \right)^2 \right] + \frac{1}{2} \\ &\times \psi \left[\sum_{r=1}^n \frac{\left(x_r^{(t)} \right)^2}{\left(1 + \sigma_r^{(t)} \right)^2} \right] \end{aligned} \quad (47)$$

با افزودن نویز به داده‌ها، معادله خروجی به صورت زیر خواهد بود:

$$\begin{aligned} y_N^{(t)} &= f_{(t)}(X, N) \\ &= f(x_1^{(t)}, x_2^{(t)}, x_3^{(t)}, \dots, x_n^{(t)}, n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_n^{(t)}) \\ &= \frac{1}{2} \times \psi \left[\sum_{r=1}^n \left(x_r^{(t)} + n_r^{(t)} \right)^2 \right] + \frac{1}{2} \\ &\times \psi \left[\sum_{r=1}^n \frac{\left(x_r^{(t)} + n_r^{(t)} \right)^2}{\left(1 + \sigma_r^{(t)} \right)^2} \right] \end{aligned} \quad (48)$$

¹ Distortion Caused by Noise (DCN)
² Gaussian Probability Distribution Function (Gaussian PDF)

$$DCN = |y_N - y| = \frac{1}{2} \times \left| \exp\left[\frac{-(x+n)^2}{2}\right] + \exp\left[\frac{-(x+n)^2}{2(1+\sigma^2)}\right] - \exp\left[\frac{-x^2}{2}\right] - \exp\left[\frac{-x^2}{2(1+\sigma^2)}\right] \right| \quad (49)$$

متغیر تصادفی n روی فضای احتمال^۱ (Ω, \mathcal{F}, P) تعریف می‌گردد که در آن داریم^[۴۱]:

- Ω فضای نمونه^۲ شامل مقادیر تصادفی نویز و در واقع همان تابع به دست آمده از آزمایشات است.
- فضای رویداد^۳ و با فضای فرآیند تصادفی^۴ است که بخشی از فضای نمونه را در بر می‌گیرد و شامل رویدادهایی است که وقوع پذیرند و در واقع احتمال وقوع بزرگتر از صفر دارند. به عنوان مثال رویداد قرار گرفتن «بزرگی نویز در بازه رویداد [-0.6745 σ_n , 0.6745 σ_n]» احتمال وقوع بالای دارد.
- P تابع اندازه احتمال رویداد^۵ است که وظیفه آن اختصاص یک عدد حقیقی نگاشت می‌کند. می‌توان از تابع چگالی احتمال به عنوان تابع اندازه احتمال رویداد استفاده نمود.

مقدار مورد انتظار یا آمید ریاضی برای اختلال ایجاد شده بوسیله نویز^۶ عبارت است از:

$$E(\mathcal{N}) = \int_{\Omega} DCN \times dP = \int_{-\infty}^{\infty} DCN \times f_N(n) dn = \int_{-\infty}^{\infty} |y_N - y| \times f_N(n) dn \quad (100)$$

با تغیرب خوبی می‌توان حدوده انتگرال گیری را به شکل زیر عرض نمود:

$$E(\mathcal{N}) = \int_{-4\sigma}^{4\sigma} DCN \times f_N(n) dn = \int_{-4\sigma}^{4\sigma} |y_N - y| \times f_N(n) dn \quad (101)$$

می‌توان فرم پیوسته تابع آمید ریاضی یعنی $E(\mathcal{N})$ را به صورت زیر گسته نمود. در حالت گسته این تابع از طریق جمع مقادیر نمونه‌ها و

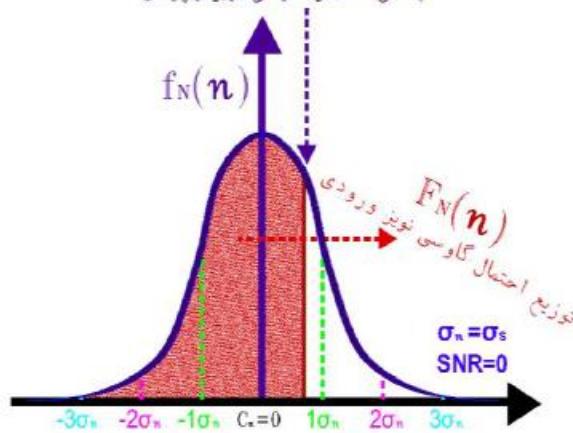
تحصی^۷ نیز گفته می‌شود، از نوع «نمایل گاوی» یا مبانگن صفر و به صورت $\mathcal{N}(0, \sigma_n^2)$ در نظر می‌گیریم و به شکل زیر تعریف می‌نماییم^[۴۱ ۴۹]:

$$F_N(n) = \int_{-\infty}^n f_N(z) dz = \frac{1}{\sqrt{2\pi} \times \sigma_n} \int_{-\infty}^n \psi\left(\frac{z^2}{\sigma_n^2}\right) dz = \frac{1}{\sqrt{2\pi} \times \sigma_n} \int_{-\infty}^n \exp\left(-\frac{1}{2} \times \frac{z^2}{\sigma_n^2}\right) dz \quad (45)$$

تابع چگالی احتمال^۸ برای نویز ورودی به شکل زیر به دست می‌آید:

$$f_N(n) = \frac{d}{dn} F_N(n) = \frac{1}{\sqrt{2\pi} \times \sigma_n} \psi\left(\frac{n^2}{\sigma_n^2}\right) = \frac{1}{\sqrt{2\pi} \times \sigma_n} \exp\left(-\frac{1}{2} \times \frac{n^2}{\sigma_n^2}\right) \quad (46)$$

چگالی احتمال گاوی نویز ورودی



شکل ۱۲. تابع توزیع احتمال و تابع چگالی احتمال گاوی برای نویز ورودی

همان طور که در شکل ۹ می‌بینیم، فرض بر این است که فدرت نویز زیاد بوده و با فدرت سیگنال برابر باشد یعنی خواهیم داشت $SNR = 0$ (dB) و در نتیجه^[۱۱]:

$$SNR = 10 \log_{10} \frac{\text{the variance of the signal}}{\text{the variance of the noise}} = 10 \log_{10} \frac{\sigma_s^2}{\sigma_n^2} = 0 \rightarrow \sigma_s = \sigma_n \quad (47)$$

آنچه که σ_s^2 واریانس سیگنال و σ_n^2 واریانس نویز می‌باشد. اکنون فرض می‌کنیم $\sigma_s = \sigma_n = \sigma' = 0.33$ باشد، در آن صورت تابع چگالی احتمال برای نویز که در حالت گسته به آن تابع جرم احتمال^۹ گویند به شکل زیر ساده می‌گردد:

$$f_N(n) = \frac{1}{\sqrt{2\pi} \times \sigma'} \exp\left(-\frac{1}{2} \times \frac{n^2}{\sigma'^2}\right) = \frac{1}{\sqrt{2\pi} \times 0.33} e^{-\frac{n^2}{2 \times 0.33^2}} = \frac{1}{0.825} e^{-\frac{n^2}{0.2178}} = 1.2e^{-4.6n^2} \quad (48)$$

اکنون با فرم داشتن یک نمونه ورودی یعنی $T=I$ ، می‌توانیم تابع دو متغیره DCN را به یک تابع یک متغیره با متغیر مستقل n تبدیل نماییم.

^۱ Probability space

^۲ Sample space

^۳ Event space

^۴ Stochastic Process space

^۵ Event Probability Function

^۶ Cumulative Distribution Function (CDF)

^۷ Probability Density Function (pdf)

^۸ Probability Mass Function (pmf)

۲-۷ تعمیم اثبات فوق برای حالتی که m ترون در لایه میانی وجود داشته باشد

تعریف ۱. فرآیند تصادفی شارا^۲ (با زمان گسته^۳) روی فضای احتمال (Ω, \mathcal{F}, P) عبارت است از دنباله‌ای از متغیرهای تصادفی مانند $\{n_r^{(t)}\}_{r \in N}$ (روی این فضا و آن را به صورت $\{n_r^{(t)}\}_{r \in N}$ نشان می‌دهیم^۴).

قرارداد. از این پس منظور از \mathbb{R}^∞ یعنی مجموعه همه دنباله‌های اعداد حقیقی^۵ و یا به عبارت دیگر مجموعه همه تابع از \mathbb{N} به \mathbb{R} که هر تابع می‌تواند یک دنباله را تولید کند. به عنوان مثال تابع نویز $n_r^{(t)}$ با «تابع توزیع احتمال گاوسی» می‌تواند بکی از این تابع باشد.^۶ [۴۰ ۳۸]

تعریف ۲. مجموعه A در \mathbb{R}^∞ را یک بازه با بعد متناهی گوییم اگر $n \in N$ و بازه‌های متناهی و نامتناهی $I_1, I_2, \dots, I_r, \dots, I_n$ موجود باشند که $A = \{N^{(t)} \in \mathbb{R}^\infty : n_r^{(t)} \in I_r, r = 1, 2, \dots, n\}$. به عنوان مثال مقدار نویز افزوده شده به ورودی $x_r^{(t)}$ یعنی $x_r^{(t)}$ که به صورت $n_r^{(t)}$ نشان داده می‌شود، در بازه $[4\sigma_n, -4\sigma_n]$ که یک بازه با بعد متناهی است فرار دارد. بعد متناهی این بازه برابر بعلو بردار نویز ورودی یعنی $N^{(t)} = [n_1^{(t)}, n_2^{(t)}, \dots, n_n^{(t)}]$ می‌باشد. رده تمام بازه‌های با بعد متناهی را با \mathcal{G} نشان می‌دهند.^۷ [۲۷]

تعریف ۳. فرض می‌کنیم که مجموعه B به صورت زیر تعریف گردد:^۸ [۴۰ ۳۸]

$$B = \{X^{(t)}, N^{(t)} \\ \in \mathbb{R}^\infty : (x_1^{(t)}, x_2^{(t)}, x_3^{(t)}, \dots, x_n^{(t)}, n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_n^{(t)}) \in B_n\} \quad (1.6)$$

- مجموعه B در \mathbb{R}^∞ را یک استوانه با بعد متناهی گوییم.
- رده تمام استوانه‌های با بعد متناهی با e_∞ نشان داده می‌شود که e_∞ یک میدان است.
- در این صورت e_∞ می‌تواند یک میدان سیگما^۹ باشد.
- از دیدگاه احتمال، میدان سیگما^{۱۰} را می‌توان به عنوان اطلاعات داده شده یک آزمایش در نظر گرفت.
- مجموعه‌های بُرل روی Ω و P از فضای احتمال (Ω, \mathcal{F}, P) به شکل (e_∞, σ) و (G, σ) تعریف می‌گردند.

هنچارسازی^{۱۱} حاصل جمع نسبت به تعداد نمونه‌ها محاسبه می‌شود و با می‌توان از تابع چگالی احتمال نویز ورودی به صورت زیر استفاده نمود:

$$E(N) = \sum_{n=-4\sigma}^{4\sigma} |y_N - y| \times f_N(n) \Delta n \quad (1.2)$$

هر چه مقدار Δn را کوچکتر در نظر بگیریم دقت محاسبه بیشتر خواهد بود. Δn را می‌توان برابر 0.001 یا 0.0001 در نظر گرفت.

اکنون تابع $E(N^2)$ را به شکل زیر به دست می‌آوریم:

$$E(N^2) = \int_{-4\sigma}^{4\sigma} (DCN)^2 \times f_N(n) dn = \int_{-4\sigma}^{4\sigma} (y_N - y)^2 \times f_N(n) dn \quad (1.3)$$

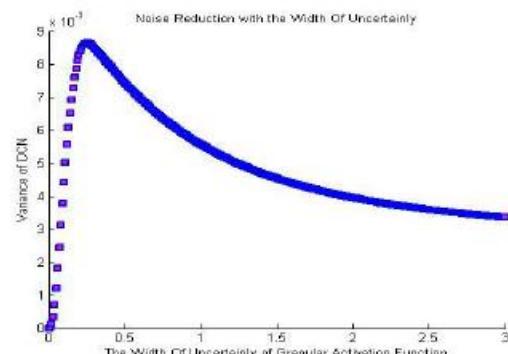
می‌توان فرم پیوسته تابع $E(N^2)$ را به صورت زیر گسته نمود:

$$E(N^2) = \sum_{n=-4\sigma}^{4\sigma} [(y_N - y)^2 \times f_N(n) \Delta n] \quad (1.4)$$

واریانس تابع DCN به شکل زیر محاسبه می‌گردد:

$$Var(N) = E(N^2) - [E(N)]^2 \quad (1.5)$$

نمودار تغییرات واریانس تابع DCN بر حسب σ مانند شکل ۱۰ به دست می‌آید. این شکل نشان می‌دهد که ابتدا با افزایش مقدار σ (تغییر انحراف استاندارد تابع فعال‌ساز گرانولی) تا سطح $\sigma' = 0.33$ (انحراف استاندارد نویز)، واریانس تابع DCN افزایش می‌باید. چرا که بهنای عدم قطعیت در تابع فعال‌ساز گرانولی هنوز قدرت ختنی نمودن اثر نویز را ندارد و تغییرات مقدار نویز سبب تغییر اختلال ایجاد شده بوسیله نویز می‌گردد. که آن نیز به نوعه خود تغییر در واریانس این اختلال را در بی‌دارد که در این مرحله افزایش می‌باشد. با افزایش بیشتر مقدار σ بهنای عدم قطعیت در تابع فعال‌ساز گرانولی بر نویز ورودی غلبه نموده و واریانس تابع DCN رو به کاهش می‌گذارد. کاهش واریانس تابع DCN به معنی آن است که با افزایش بهنای عدم قطعیت در تابع فعال‌ساز گرانولی، مقدار تابع DCN حول میانگین آن پراکندگی کمتری دارد و چون تابع توزیع احتمال نویز ورودی، گاوسی با تُرمال با میانگین صفر می‌باشد، پس تابع DCN بیشتر به سمت صفر میل کرده و در واقع اختلال ایجاد شده بوسیله نویز کاهش یافته است.



شکل ۱۳. تغییرات واریانس تابع DCN بر حسب بهنای عدم قطعیت یعنی σ

² Countable Stochastic Process

³ Discrete Time

⁴ Cylinder

⁵ σ -field

¹¹ Normalizing

• اگر برای $N \in \mathbb{N}$ یک اندازه احتمال P_r روی (\mathbb{R}^∞, B) در دست داشته باشیم؛ می‌توانیم یک اندازه احتمال P روی $(\mathbb{R}^\infty, B_\infty)$ طوری بسازیم که تحدید P به همان P_r شود. یعنی داشته باشیم:

$$\forall B \in B_r; \quad P \left(\left\{ X^{(t)}, \mathcal{N}^{(t)} \in \mathbb{R}^\infty : (x_1^{(t)}, x_2^{(t)}, n_1^{(t)}, n_2^{(t)}) \in B \right\} \right) = P_r(B) \quad (113)$$

• اگر برای $r+1 \in N$ یک اندازه احتمال P_{r+1} روی (\mathbb{R}^∞, B) در دست داشته باشیم؛ می‌توانیم یک اندازه احتمال P روی $(\mathbb{R}^\infty, B_\infty)$ طوری بسازیم که تحدید P به همان P_{r+1} شود. یعنی داشته باشیم:

$$\forall B \in B_{r+1}; \quad P \left(\left\{ X^{(t)}, \mathcal{N}^{(t)} \in \mathbb{R}^\infty : (x_1^{(t)}, x_2^{(t)}, n_1^{(t)}, n_2^{(t)}) \in B \right\} \right) = P_{r+1}(B) \quad (114)$$

پس با هر تعداد ورودی قادر به ساختن یک اندازه احتمال P روی $(\mathbb{R}^\infty, B_\infty)$ خواهیم بود.

قضیه وجود نکاشت^۱ شبکه عصبی پیشو^۲ کلموگروف: هر تابع پیوسته $f(x^{(t)}, n^{(t)}): [0, 1]^n \rightarrow R^m$ را می‌توان به طور دقیق توسط یک شبکه عصبی سه لایه‌ای پیشو^۳، که دارای n نُرون در لایه ورودی و $(2n+1)$ نُرون در لایه پنهان و m نُرون در لایه خروجی می‌باشد تحقیق بخشد. طبق این قضیه چنین شبکه‌ای وجود دارد^[۴۲].

قضیه وجود نکاشت شبکه عصبی پس انتشار^۴ کلموگروف: برای هر تابع $f(x^{(t)}, n^{(t)}): [0, 1]^n \rightarrow R^m$ که L_2 باشد یعنی انگرال $\int_{[0, 1]^n} |f(x^{(t)}, n^{(t)})|^2 dx$ موجود باشد، یک شبکه عصبی پس-انتشار سه لایه وجود دارد که می‌تواند تابع f را با دقت میانگین مربع خطای یک عدد کسری ثابت مثبت به نام $d < e < 0$ تغیر بزند.

فضای L_2 شامل هر تابعی که در یک مسئله عملی وجود دارد می‌شود. به عنوان نمونه شامل تمام توابع ناپیوسته که به صورت تکه‌ای نیز پیوسته هستند می‌شود. این قضیه ثابت می‌کند که همیشه سه لایه کافیست. هر چند در عمل استفاده از ۴ یا ۵ یا حتی لایه‌های بیشتر مرسوم است. زیرا بسیاری از مسائل برای حل، توسط شبکه سه لایه‌ای، نیازمند تعداد زیادی نُرون در لایه پنهان خود می‌باشند. که این امر به کند شدن سرعت پردازش منجر می‌شود. بالاخره هر چند این قضیه تفسیم می‌کند که شبکه‌های عصبی چند لایه با وزن‌های صحیح، قادر به نگاشت

• مجموعه B_∞ را به صورت $B_\infty = \sigma(e_\infty) = \sigma(\mathcal{G}_\infty)$ تعریف می‌کیم.

گزاره: اثبات می‌گردد که هر فرآیند تصادفی مانند فرآیند تصادفی شمارای $\{n_r^{(t)}\}_{r \in N}$ یک بردار تصادفی به صورت $\mathcal{N}^{(t)}: (\Omega, \mathcal{F}, P) \rightarrow (\mathbb{R}^\infty, B_\infty)$ دست می‌دهد^[۴۱ ۳۹].

قضیه توسع گلموگروف^۱: فرض کنید که برای هر $n \in N$ یک اندازه احتمال P_n روی (\mathbb{R}^∞, B) در دست است. می‌خواهیم یک اندازه احتمال P روی $(\mathbb{R}^\infty, B_\infty)$ طوری بسازیم که تحدید P به همان P_n شود. یعنی داشته باشیم^[۴۱ ۳۹]:

$$\forall B \in B_n; \quad P \left(\left\{ X^{(t)}, \mathcal{N}^{(t)} \in \mathbb{R}^\infty : (x_1^{(t)}, x_2^{(t)}, x_3^{(t)}, \dots, x_n^{(t)}, n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_n^{(t)}) \in B \right\} \right) = P_n(B) \quad (115)$$

می‌دانیم که $\mathcal{F} \subset \Omega$ است. اگر مجموعه F را به عنوان مجموعه‌ای از درایوهای بردار $\mathcal{N}^{(t)}$ در نظر بگیریم و F یک مجموعه شمارا و زیر-مجموعه R باشد. و با توجه به این که می‌دانیم^۲ دنباله-ای از متغیرهای تصادفی است آن‌گاه در صورت برقراری شرایط زیر:

• $P(. \geq 0, \quad (116)$

• $\sum_{n_{n+1}^{(t)} \in F} P(n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_{n+1}^{(t)}) = P(n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_n^{(t)}), \quad (117)$

• $\sum_{n_1^{(t)} \in F} P(n_1^{(t)}) = 1, \quad (118)$

فرآیند شمارای $\{x_r^{(t)}\}_{r \in N}$ که می‌تواند دارای ویژگی غیرخطی و با آشوبی باشد، چنان موجود است که:

$$P(x_1^{(t)} \leftarrow x_1^{(t)} + n_1^{(t)}, \dots, x_n^{(t)} \leftarrow x_n^{(t)} + n_n^{(t)}) = P(n_1^{(t)}, n_2^{(t)}, n_3^{(t)}, \dots, n_n^{(t)}) \quad (119)$$

برای تعیین تعداد ورودی‌ها از یک ورودی به چند ورودی؛ از قضیه توسع گلموگروف و اثبات به کمک استخراج ریاضی^۳ به شکل زیر استفاده می‌کیم:

• اگر برای $1 \in N$ یک اندازه احتمال P_1 روی (\mathbb{R}^∞, B) در دست داشته باشیم؛ می‌توانیم یک اندازه احتمال P روی $(\mathbb{R}^\infty, B_\infty)$ طوری بسازیم که تحدید P به P_1 شود. یعنی داشته باشیم:

$$\forall B \in B_1; \quad P \left(\left\{ X^{(t)}, \mathcal{N}^{(t)} \in \mathbb{R}^\infty : (x_1^{(t)}, n_1^{(t)}) \in B \right\} \right) = P_1(B) \quad (112)$$

² Mapping

³ Feed Forward Neural Network (FFNN)

⁴ Feed forward three layers neural network

⁵ Back Propagation Neural Network (BPNN)

¹ Kolmogorov

- Transactions on Fuzzy Systems, vol. 16, no. 6, pp. 1411-1424, December 2008.
- [8] S. Guohua, L. Mingfeng, L. Teik C, "Enhanced Filtered-X Least Mean M-estimate Algorithm for Active Impulsive Noise Control," Applied Acoustics, 90: pp. 31-41, 2015.
- [9] B. Santosh Kumar, D. Debi Prasad, S. Bidyadhar, "Functional Link Artificial Neural Network Applied to Active Noise Control of a Mixture from Tonal and Chaotic Noise," Applied Soft Computing, 23: pp. 51-60, 2014.
- [10] M. Ahmadieh Khanesar, E. Kayacan, M. Teshnehab, and O. Kaynak, "Analysis of the Noise Reduction Property of Type-2 Fuzzy Logic Systems Using a Novel Type-2 Membership Function," IEEE Transactions on Fuzzy Systems, Man, and Cybernetics-part B: Cybernetics, vol. 41, no. 5, October 2011.
- [11] M. Ahmadieh Khanesar, M. Teshnehab, E. Kayacan, and O. Kaynak, "A Novel Type-2 Fuzzy Membership Function: Application to the Prediction of Noisy Data," In Computational Intelligence for Measurement Systems and Applications (CIMSA), 2010 IEEE International Conference on, pp. 128-133. IEEE, 2010.
- [12] B. Anja, et al, "Wavelet Based Noise Reduction in CT-images Using Correlation Analysis," Medical Imaging, IEEE Transactions on, 27.12, pp. 1685-1703, 2008.
- [13] S. Stefan, et al, "Fuzzy Random Impulse Noise Reduction Method," Fuzzy Sets and Systems, 158.3, pp. 270-283, 2007.
- [14] S. Stefan, et al, "A Fuzzy Impulse Noise Detection and Reduction Method," Image Processing, IEEE Transactions on, 15.5, pp. 1153-1162, 2006.
- [15] T. Li; J. Jean, "Adaptive Volterra Filters for Active Control of Nonlinear Noise Processes," Signal Processing, IEEE Transactions on, 49.8, pp. 1667-1676, 2001.
- [16] L. Chien-Cheng, Y.-C. Chiang, C.-Y. Shih and C.-L. Tsai, "Noisy Time-series Prediction Using M-estimator based Robust Radial Basis Function Neural Networks with Growing and Pruning Techniques," Expert Systems with Applications 36, no. 3, 4717-4724, 2009.
- [17] Y. Y. Yao, "Human-inspired Granular Computing," Novel Developments in Granular Computing: Applications for Advanced Human Reasoning and Soft Computation, pp. 1-15, 2010.
- [18] Z. Meciarova, "Granular Computing and its Applications in RBF with Cloud Activation Function," Journal of Informational, Control and Management Systems, vol. 7, Issue 1, pp. 7-16, 2009.

و تغريب هر تابع L_2 دلخواه است؛ ولی در مورد رسیدن و با نرسیدن به این وزنها، هیچ قانون یادگیری تضمینی موجود نیست [۴۲].

پس وقتی یک شبکه عصبی پس انتشار سه لایه مانند شبکه عصبی RBF گرانولی با یک نرون در لایه میانی و آموزش پارامترها به روش RBF «گرادیان نزولی» بتواند با تغريب بهتری نسبت به یک شبکه عصبی با همان تعداد نرون در لایه میانی و همان روش آموزش، یک تابع غیرخطی یا آشوب را تعقیب بخشد، به طور حتم با چند نرون در لایه میانی نیز این برتری به وفور خواهد پیرست. زیرا تابع غیرخطی و تابع آشوب به کار رفته، هر دو L_2 می‌باشد.

از طرفی دو قضیه «وجود نگاشت شبکه عصبی پیشرو گلسوگرف» و «وجود نگاشت شبکه عصبی پس انتشار گلسوگرف» محدود به روش آموزش خاصی نیستند، پس در تعمیم از دو نرون به چند نرون در لایه میانی، می‌توان نتیجه گرفت که یک شبکه عصبی پس انتشار سه لایه مانند شبکه عصبی RBF گرانولی با آموزش پارامترها به روش K-Means، بتواند با تغريب بهتری نسبت به یک شبکه عصبی RBF با همان تعداد نرون در لایه میانی رفتار نماید.

مراجع

- [1] X. Wu, Y. Wang, W. Liu, Z. Zhu, and Y. Tan, "Application of Nonlinear Filtering Trained RBF Networks to Multi-step Prediction of Time-series with Delayed Observations," Journal of Information & Computational Science vol. 7: 3, pp. 385-393, 2011. Available at <http://www.joics.com>.
- [2] M. Bahita, and K. Belarbi, "Neural Feedback Linearization Adaptive Control for Affine Nonlinear Systems Based on Neural Network Estimator," Serbian Journal of Electrical Engineering vol. 8, no. 3, pp. 307-323, November 2011.
- [3] D. R. Brillinger, "Time Series: Data Analysis and Theory," vol. 36, Siam, 2001.
- [4] Y. Yao, "Interval Sets and Interval-set Algebras," In Cognitive Informatics, ICCT'09, 8th IEEE International Conference on, pp. 307-314, 2009.
- [5] X. Gao, "Some properties of continuous uncertain measure," International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, vol. 17, no. 3, pp. 419-426, 2009.
- [6] C.-F. Juang, R.-B. Huang and Y.-Y. Lin, "A recurrent self-evolving interval type-2 fuzzy neural network for dynamic system processing," Fuzzy Systems, IEEE Transactions on 17, no. 5, pp. 1092-1105, 2009.
- [7] C.-F. Juang, and Y. W. Tsao, "A self-evolving interval type-2 fuzzy neural network with online structure and parameter learning," IEEE

- [31] B. Henon, "A Two Dimensional Mapping with a Strange Attractor," *Communications in Mathematical Physics*, vol. 50, issue 1, pp. 69-77, 1976.
- [32] E. N. Lorenz, "Deterministic Nonperiodic Flow," *Journal of the Atmospheric Sciences* 20, no. 2, pp. 130-141, 1963.
- [33] M. Teshnehab, and K. Watanabe, "Intelligent Control Based on Flexible Neural Networks," *Kluwer Academic publisher*, 1999.
- [34] A. Lapedes, and R. Farber, "Nonlinear Signal Processing Using Neural Networks," *IEEE Conference on Neural Information Processing System, Natural and Synthetic. Proc., Mag.*, pp. 422, 1987.
- [35] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning Internal Representations by Back Propagation Errors," *Nature*, 323, pp. 533-536, 1986.
- [36] V. Seydi Ghomsheh, M. Aliyari Shoorehdeli, and M. Teshnehab, "Training ANFIS structure with modified PSO algorithm," *15th Mediterranean Conference on Control & Automation*, July 27-29, 2007, Athens-Greece.
- [37] D. Kukolj and E. Levi, "Identification of complex systems based on neural and Takagi-Sugeno fuzzy model," *IEEE Trans. Syst., Man, Cybern. B, Cybern.*, vol. 34, no. 1, pp. 272-282, Feb. 2004
- [38] V. Kreinovich, "From Interval and Probabilistic Granules to Granules of Higher Order," 2010.
- [39] P. Billingsly, "Probability and Measure," John Wiley & Sons, 2008.
- [40] S. Resnick, "Adventures in stochastic processes," Birkhäuser, Boston, 1992.
- [41] A. Papoulis, and S. U. Pillai, "Probability, Random Variables and Stochastic Processes." Tata McGraw-Hill Education, 2002.
- [۴۲] خاکی صدیق، علی (۱۳۸۳). ارزیابی روش‌های پیش‌بینی قیمت سهام و ارائه مدل بهینه. پژوهشکده بولی و بانک مرکزی جمهوری اسلامی ایران.
- [۴۳] علیاری شوره دلی، مهدی، محمد شنه لب و علی خاکی صدیق (۱۳۸۳). پیش‌بینی کوتاه مدت آنودگی هوا با کمک شبکه‌های عصبی پرسپترون چندلایه و خط حافظه دار تا خیر ششین کنفرانس سراسری سیستم‌های هوشمند، کرمان، دانشگاه شهید باهنر کرمان. http://www.civilica.com/Paper-ICS06-ICS06_025.html
- [۴۴] ظهوری زنگ، بخار و عباس شولانی (۱۳۷۸). شیوه‌ساز سیمولاتور شبکه‌های HVDC/AC با گام بهینه. پانزدهمین کنفرانس بین‌المللی برق، تهران، شرکت توابیر، پژوهشگاه نیرو، http://www.civilica.com/Paper-PSC15-PSC15_067.html
- [19] Y. Yao, and Z. Ning, "Granular Computing," *Wiley Encyclopedia of Computer Science and Engineering* (2008).
- [20] S. Dick, A. Tappenden, C. Badke, and O. Olarewaju, "A Novel Granular Neural Network Architecture," In *Fuzzy Information Processing Society, NAFIPS'07. Annual Meeting of the North American*, pp. 42-47, IEEE, 2007.
- [21] B. Andrzej, and W. Pedrycz, "The Roots of Granular Computing," In *GrC*, pp. 806-809, 2006.
- [22] J. Abdi, B. Moshiri, and A. Khaki-Sedigh, "Comparison of RBF and MLP Neural Networks in Short-term Traffic Flow Forecasting," In *Power, Control and Embedded Systems (ICPCES), 2010 International Conference on*, pp. 1-4, IEEE, 2010.
- [23] D. Marcek, M. Marcek, and J. Babel, "Granular RBF NN Approach and Statistical Methods Applied to Modeling and Forecasting High Frequency Data," *International Journal of Computational Intelligence Systems*, vol. 2, no. 4, pp. 353-364, December, 2009.
- [24] G. B. Huang, P. Saratchandran, and N. Sundararajan, "A Generalized Growing and Pruning RBF (GGAP-RBF) Neural Network for Function Approximation," *IEEE Transactions on Neural Networks*, vol. 16, no. 1, pp. 57-67, January 2005.
- [25] N. Jankowski, and V. Kadirkamanathan, "Statistical Control of Growing and Pruning in RBF-Like Neural Networks," In *Third Conference on Neural Networks and Their Applications*, pp. 663-670, 1997.
- [26] J.-S. Roger Jang, and C.-T. Sun, "Functional Equivalence between Radial Basis Function Networks and Fuzzy Inference Systems," *IEEE Transactions on Neural Networks*, vol. 4, no. 1, pp. 156-159, January 1993.
- [27] C. H. Skiadas, and C. Skiadas, "Chaotic Modeling and Simulation: Analysis of Chaotic Models, Attractors and Forms," Chapman and Hall/CRC Press is an imprint of Taylor and Francis Group, LLC, 2009, ISBN: 978-1-4200-7900-5 (hardcover: alk. paper).
- [28] J. Principe and J.-M. Kou, "Dynamic Modeling of Chaotic Time-series with Neural Networks," *Advances in Neural Information Processing Systems*, pp. 311-318, 1995.
- [29] V. Isham, "Statistical Aspects of Chaos, A Review," in: *Networks and Chaos-Statistical and Probabilistic Aspects*, pp. 124-200, Springer US, 1993.
- [30] M. C. Mackey, and L. Glass, "Oscillation and Chaos in Physiological Control System," *Sicence* 197, no. 4300, pp. 287-289, 1977.