

بررسی پایداری استاتیکی ولتاژ با استفاده از ماشین بردار پشتیبان و شبکه عصبی

مهدی حاجیان^(۱) - اصغر اکبری فرود^(۲) - حسین نوروزیان^(۳)

(۱) کارشناس ارشد - دانشکده برق و کامپیوتر، دانشگاه سمنان

(۲) دانشیار - دانشکده برق و کامپیوتر، دانشگاه سمنان

(۳) کارشناس - دانشکده برق و کامپیوتر، دانشگاه سمنان

تاریخ پذیرش: بهار ۱۳۹۲

تاریخ دریافت: تابستان ۱۳۹۱

خلاصه: پایداری ولتاژ یک مسئله اساسی در سیستم قدرت می‌باشد. در این مقاله پایداری ولتاژ از حیث استاتیکی، و کاربرد شبکه عصبی و SVM در تخمین حد پایداری و نیز پیش‌بینی پایداری ولتاژ بررسی شده است. پایداری ولتاژ در دو بخش مورد ارزیابی قرار گرفته است. در بخش اول، محاسبه حاشیه پایداری استاتیکی ولتاژ به وسیله شبکه عصبی RBF بیان می‌شود. مزیت روش استفاده شده، دقت بالای آن در تشخیص حاشیه پایداری ولتاژ به صورت بهنگام است. بخش دوم به پیش‌بینی فروپاشی ولتاژ به کمک شبکه عصبی PNN و SVM می‌پردازد. نتایج به دست آمده نشان می‌دهد که زمان و تعداد نمونه‌های آموزش SVM کمتر از شبکه‌های عصبی است. در این مقاله، مدلی جدید از تولید نمونه‌های آموزشی سیستم تشخیص، با استفاده از منحنی توزیع نرمال بار هر فیدر، به کار گرفته شده است. در تحلیل پایداری ولتاژ از شاخص‌های مشهور VSM و L استفاده گردیده است. برای نشان دادن اعتبار روش‌های پیشنهادی، شبکه ۱۴ باسه IEEE و شبکه واقعی استان یزد مورد استفاده قرار گرفته است.

کلمات کلیدی: حاشیه پایداری ولتاژ، ارزیابی و پیش‌بینی پایداری ولتاژ، ماشین بردار پشتیبان (SVM).

۱- مقدمه

نمود. در زمینه ارزیابی پایداری ولتاژ، مطالعاتی صورت گرفته است. در مرجع [۶] کاربرد شبکه عصبی در تخمین VSM بحث و بررسی شده است. در مقاله [۷] از سیستم خبره فازی برای تخمین حد پایداری ولتاژ بهره گرفته شده است. در مرجع [۸] بر اساس حد پایداری ولتاژ، حوادث ولتاژی طبقه‌بندی شده و در مرجع [۹] چند شاخص مهم تعیین کننده حد پایداری ولتاژ، با استفاده از شبکه عصبی تخمین زده شده است. در مرجع [۱۰] شبکه عصبی مدار شعاعی^۲ (RBF) برای تعیین حد بارپذیری سیستم، به کار رفته است.

اما در نقطه مقابل، هدف از پیش‌بینی پایداری ولتاژ تعیین حد پایداری ولتاژ نیست. در حقیقت در این حالت پرسش اصلی این است که، آیا به ازای شرایط موجود پایداری ولتاژ حفظ خواهد شد یا خیر [۹].

در مرجع [۱۱] با شبکه عصبی RBF فروپاشی ولتاژ سیستم تخمین زده شده است. در مقاله [۱۲] شبکه عصبی^۳ MLP و SVM^۴ جهت پیش‌بینی پایداری ولتاژ استفاده شده است. در [۱۳] شاخصی جهت پیش‌بینی بهنگام فروپاشی ولتاژ ارائه شده است. همچنین در مرجع [۱۴] با استفاده از شبکه عصبی و شاخص L، به پیش‌بینی پایداری ولتاژ پرداخته است. در مراجع [۱۵] و [۱۶] حد استاتیکی پایداری

سیستم‌های قدرت الکتریکی امروزه یکی از مهمترین منابع تولید انرژی محسوب می‌شوند. با رشد روزافزون مصرف انرژی به پیچیدگی شبکه‌های سراسری برق نیز افزوده شده است. رشد چشمگیر شبکه‌های قدرت سبب شده که برای افزایش بهره‌وری شبکه، سیستم‌های قدرت در نزدیکی حاشیه پایداری و با بیشترین میزان باردهی خود کار کنند. از طرفی کمبود توان راکتیو در شبکه‌های قدرت، سیستم را به سوی ناپایداری می‌کشاند و منجر به ایجاد افت و نوسانات ولتاژ می‌گردد. هنگامی که یک باس دچار ناپایداری ولتاژ گردید، ممکن است این اغتشاش به باس‌های دیگر شبکه سرایت کرده و سبب فروپاشی ولتاژ گردد [۱].

در تحلیل پایداری ولتاژ دو موضوع حائز اهمیت است [۲]:

۱- ارزیابی پایداری ولتاژ، ۲- پیش‌بینی پایداری ولتاژ.

ارزیابی پایداری ولتاژ، به دنبال تعیین حد پایداری ولتاژ^۱ (VSM) یا حداکثر بارپذیری سیستم می‌باشد. از جمله روش‌هایی که در تعیین حداکثر بارپذیری سیستم کاربرد دارند می‌توان به روش یکتایی تفکیک شده [۳]، آنالیز مقدار ویژه [۴] و روش پخش بار تداومی [۵] اشاره

مهمترین قابلیت PNN و RBF در مقایسه با شبکه‌های دیگر، سرعت بالای آموزش آن می‌باشد. به علاوه در زمینه کلاسه‌بندی داده‌ها، PNN دارای دقت بالایی نسبت به MLP می‌باشد. در ادامه، ابتدا معرفی و شبیه‌سازی ارزیابی پایداری استاتیکی ولتاژ و نتایج حاصل از آن بیان می‌شود. سپس پیش‌بینی وضعیت استاتیکی ولتاژ بررسی و نتایج و تحلیل‌های مرتبط با آن ارائه خواهد شد.

۲- ارزیابی پایداری استاتیکی با استفاده از روش منحنی P-V

کارکرد خطوط انتقال و نیروگاهها (سیستم قدرت) در نزدیکی حاشیه پایداری خود، امکان ناپایداری سیستم به دلیل افزایش بار و خروج واحدهای نیروگاهی را افزایش داده است. به همین دلیل پیش‌بینی و تشخیص ناپایداری ولتاژ در سیستم‌های قدرت بسیار حائز اهمیت بوده و باعث افزایش امنیت شبکه می‌گردد. لذا با توجه به اهمیت حفظ پایداری ولتاژ، بررسی وضعیت پایداری ولتاژ شبکه‌های قدرت، با در نظر گرفتن وقوع خطاهای احتمالی، ضروری می‌باشد.

در روشهای استاتیکی با استفاده از حل معادلات جبری سیستم قدرت و با ملاحظه دامنه گسترده‌ای از شرایط سیستم و تعداد زیاد روندهای اختلال، به مطالعه پایداری شبکه به صورت میان‌مدت و بلندمدت پرداخته می‌شود، که نسبت به روشهای دینامیکی از گسترش کمتری برخوردار است. در شبکه‌های قدرت تغییر آهسته و مداوم نقطه کار سیستم به واسطه افزایش بار، می‌تواند باعث ناپایداری ولتاژ گردد که برای بررسی اینگونه ناپایداری‌ها، روشهای استاتیکی مناسب‌تر می‌باشد [۲۰].

در مطالعه پایداری استاتیکی ولتاژ از روشهایی همچون: آنالیز مودال، آنالیز مقادیر ویژه، نظریه انشعاب، بررسی نقطه فروپاشی، شاخص بردار tangent، آنالیز حساسیت، روش پخش بار تداومی و ... می‌توان استفاده نمود. این روشها اصولاً بر پایه محاسبات پخش بار و رسم منحنی‌های P-V و محاسبات مقادیر ویژه ماتریس جاکوبین استوارند [۶].

۳- شبکه RBF

شبکه‌های تابع مدار شعاعی، بیشترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند، که اساساً به عنوان گونه‌ای از شبکه‌های عصبی حیاتی نو یافته است و مزیت عمده آن‌ها طبقه‌بندی الگوهای با فضای غیر خطی است. شبکه‌های عصبی شعاعی به واسطه آموزش سریع و فراگیر و نیز تنها با داشتن یک لایه مخفی دارای چنین خاصیتی می‌باشد [۱۱]. این شبکه دارای نرخ طبقه‌بندی بهتری نسبت به سایر روش‌ها، مانند MLP است.

۳-۱- ساختار شبکه عصبی شعاعی

این شبکه متشکل از سه لایه است. لایه اول لایه ورودی، که در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و فضای بعد آن برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک پذیر غیرخطی دارد [۱۱].


ولتاژ بر اساس یک شاخص استاتیکی و با استفاده از شبکه‌های عصبی PNN و SVM مورد بررسی قرار گرفته است.

به علت پیچیدگی، تعداد کلاس‌های نسبتاً زیاد و بزرگ بودن ابعاد بردار ویژگی، به دست آوردن جواب قابل قبول در طبقه‌بندی پایداری ولتاژ، با استفاده از روش‌های معمول یادگیری ماشین، تقریباً امکان‌پذیر نمی‌باشد. در این پژوهش، از سه طبقه‌بندی‌کننده مشهور، شبکه‌های عصبی RBF، شبکه عصبی احتمالاتی^۵ (PNN) و ماشین‌های بردار پشتیبان استفاده شده است. در این مقاله، از شبکه عصبی RBF برای تعیین حد پایداری استاتیکی ولتاژ بهره برده‌ایم. همچنین، توسط شاخص مشهور L و به کمک SVM و شبکه عصبی PNN پیش‌بینی پایداری ولتاژ انجام شده است.

برتری روش پیشنهادی در تعیین حد پایداری استاتیکی ولتاژ، تخمین مرز مگواتی است که نتایج ارزشمندی از آن قابل برداشت است. از دیگر ویژگی‌های این پژوهش، استفاده از روش جدید SVM در پیش‌بینی پایداری استاتیکی ولتاژ و همچنین مقایسه شبکه عصبی PNN و SVM در این حوزه، می‌باشد. در واقع ماشین بردار پشتیبان یک شبکه عصبی پیشرفته می‌باشد که برخی از عیوب ابزار پیشین (مانند عدم تعمیم پذیری بالا، عدم دقت، حساسیت به نویز و...) را برطرف نموده است. در این مقاله، مدلی متفاوت، از تولید نمونه‌های آموزشی، بیان شده است. به دلیل ماهیت تصادفی بار روی هر باس، سیستم قدرت، یک منحنی توزیع نرمال برای مقدار بار روی هر باس، در نظر گرفته می‌شود. این روش، قابلیت در نظر گرفتن جامع احتمالات رشد یا کاهش بار یک باس را، اطراف میانگین بار آن دارا می‌باشد.

بر خلاف مقالات چاپ شده که فقط یک جنبه از مطالعات پایداری ولتاژ را مورد بررسی قرار می‌دهند، در این مقاله، مطالعه‌ای جامع در این حوزه انجام گرفته است. همچنین، با سه ابزار که در حوزه تشخیص الگو و رگرسیون سطح اول مطالعات تحقیقاتی را تشکیل می‌دهند، مدل‌سازی و برای مانی‌تورینگ پایداری ولتاژ به کار رفته است. اکثر مقالاتی که در زمینه ارزیابی پایداری ولتاژ، به ویژه پیش‌بینی حد پایداری ولتاژ به وسیله شاخص L و VSM و شاخص‌های دیگر، با شبکه عصبی MLP مطالعاتی را انجام داده‌اند. معتبرترین شاخص در این حوزه VSM می‌باشد. در مقاله پیشنهادی، ترکیب این شاخص با یکی از بهترین ابزار رگرسیون (شبکه عصبی RBF)، برای ارزیابی پایداری ولتاژ به کار رفته است. همچنین، در زمینه پیش‌بینی پایداری ولتاژ با شاخص L مطالعات کمی صورت گرفته است. در مقاله پیشنهادی، یک روش هوشمند پیشرفته و مقایسه‌ای به منظور یافتن ساختار تخمین و پیش‌بینی پایداری و ناپایداری ولتاژ سیستم قدرت ارائه شده است. در این بخش از دو ابزار طبقه‌بندی قدرتمند (PNN و SVM) استفاده شده است. نکته قابل توجه آن است که ترکیب شاخص L با SVM، ساختاری جدید و موثر برای پیش‌بینی پایداری ولتاژ ایجاد می‌نماید. نتایج مقاله گویای این مزیت می‌باشد.

پایداری ولتاژ (VSM) عنوان می‌شود [۶]. برای محاسبه VSM کافی است منحنی P-V ترسیم شده و فاصله مورد نظر محاسبه شود. در شبیه‌سازی صورت گرفته از شبکه برق استان یزد استفاده شده و با کمک نرم‌افزار Digsilent، حاشیه پایداری ولتاژ برای هر باس بار، به وسیله رسم منحنی P-V و محاسبه فاصله نقطه کار فعلی سیستم با نقطه فروپاشی ولتاژ محاسبه گردیده است. به دلیل ماهیت تصادفی بار در شبکه برای هر باس بار، یک منحنی توزیع نرمال با میانگین بار پایه و انحراف معین لحاظ شده (شکل (۲)) و در هر مرحله افزایش بار (اغتشاش)، میانگین منحنی‌های توزیع نرمال، افزایش یافته و تعدادی نمونه تصادفی از منحنی برداشت شده است. ضریب توان بار، ثابت است و افزایش بار به معنی افزایش توان ظاهری، می‌باشد. شش باس بار، برای استخراج داده در نظر گرفته شده است. بار باسها، جهت استخراج داده از شبکه، نسبت به بار پایه با انحراف معیار ۰/۶ و ضریب رشد بار ۲۰ درصد انتخاب شده است. بار پایه شبکه، به صورت بار متعادل (که باس‌ها نزدیک به 1pu است) می‌باشد. بیش از ۱۶۰ داده جهت مرحله آموزش از سیستم قدرت برداشت شده است. شبکه برق استان یزد در شکل (۳) نشان داده شده است.



شکل (۲): برخی از منحنی توزیع نرمال به کار گرفته شده در ارزیابی ولتاژ

Fig. (2): Some normal distribution curves used for VSA

۴-۱ تعیین پارامترهای بهینه

برای رسیدن به پارامترهای بهینه تاثیر دو پارامتر اندازه سطح گسترش (spread) و تعداد نرون‌های شبکه عصبی، جداگانه بر روی میزان خطای متوسط مورد ارزیابی قرار گرفته است. شماره سری بیان شده در شکل (۴) بیانگر مقدار عددی سطح گسترش می‌باشد. شکل (۴) تغییرات خطای متوسط میانگین بر حسب تعداد نرونهای شبکه عصبی (تعداد تابع شعاع مداری مختلف) به ازای سطح‌های مختلف گسترش را نشان می‌دهد (البته تعداد نمونه‌های مجموعه آموزشی با توجه به شکل، برابر ۱۶۴ داده در نظر گرفته شده است). همان طور که مشاهده می‌شود الگوی تغییرات به ازای سطح گسترش مختلف، تقریباً یکسان است. علاوه بر این با افزایش تعداد نرون‌ها خطا کاهش می‌یابد. نمودارهای سری‌های ۳ تا ۱۱ دارای بیشترین شیب نزول خطا و کمترین تعداد نرون لازم هستند. که در این نمودار مشاهده می‌شود ابتدا خطای میانگین با تغییرات سطح کاهش می‌یابد و بعد از رسیدن به یک نقطه مینیمم خطا افزایش پیدا می‌کند.

(۵)

سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند. تابع لایه پنهان دارای رابطه‌ای مطابق زیر است:

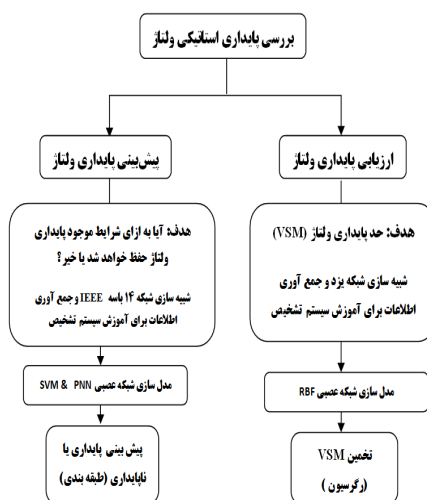
$$F(x) = \sum_{j=1}^p w_j \phi(\|x - u_j\|) \quad (1)$$

تعداد کل نرون‌های لایه پنهان p و اتصال سیناپسی نرون‌ها است. بردار u_j را مرکز گوسی می‌نامیم و x بردار ورودی می‌باشد. تابع کرنل ϕ ، به عنوان تابع پاسخ نرون در نظر گرفته می‌شود. توضیحات تکمیلی در خصوص شبکه RBF در ضمیمه الف آمده است.

۴- شبیه‌سازی و تولید داده

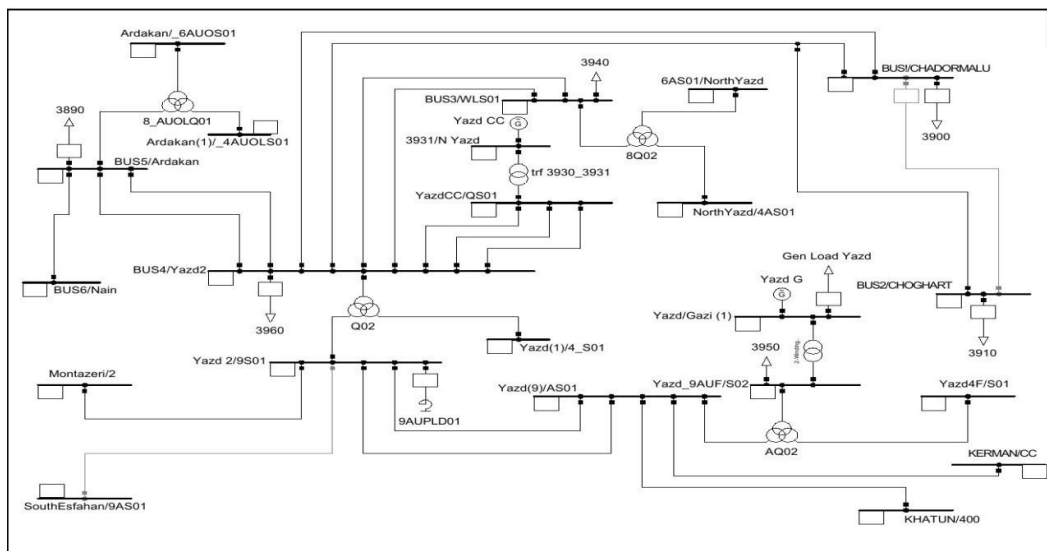
فلوچارت شکل (۱)، روش پیشنهادی و همچنین بخشهای کار را به وضوح نشان می‌دهد. در این بخش، سیستمی طراحی شده که مزیت بزرگ آن نسبت به سیستم‌های VSA دیگر، استفاده بهنگام از آن در شبکه به دلیل زمان عملکرد کوتاه آن می‌باشد.

در بررسی حد پایداری استاتیکی ولتاژ، از شبکه قدرت استان یزد به عنوان یک سیستم واقعی، استفاده گردیده و برای این مطالعه، از روش پخش بار تناوبی استفاده می‌شود.

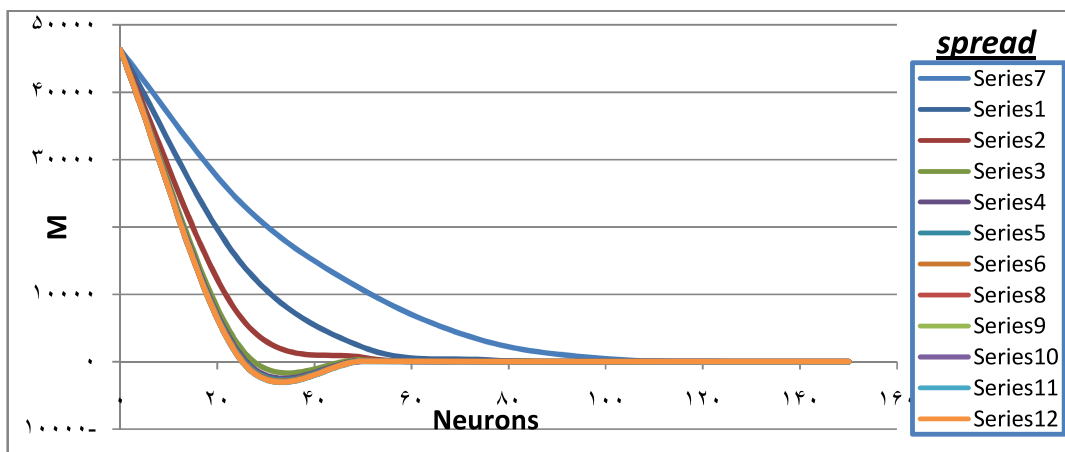


شکل (۱): فلوچارت روند پیشنهادی برای بررسی پایداری استاتیکی ولتاژ
Fig. (1): Flowchart of the proposed method for voltage stability assessment (VSA)

نمونه‌های آموزشی شامل مولفه‌های ورودی و خروجی مسئله مورد نظر هستند که هر نمونه آموزشی، یکی از نقاط کار مسئله را توصیف می‌کند. مقادیر توان ظاهری و اندازه ولتاژ هر باس بار شبکه، به عنوان مولفه‌های ورودی در نظر گرفته شده است. در این بخش، شاخصی برای تعیین آستانه ایمنی شبکه قدرت از نظر پایداری ولتاژ، به عنوان مولفه‌های خروجی نمونه‌های آموزشی، انتخاب شده است. این شاخص نشان می‌دهد که شرایط کار کنونی شبکه قدرت، چه اندازه با نقطه فروپاشی ولتاژ فاصله دارد. هر چه این فاصله بیشتر باشد شبکه قدرت از نظر امنیت ولتاژ وضعیت بهتری خواهد داشت. این فاصله، آستانه



شکل (۳): شبکه قدرت یزد
Fig. (3): Yazd power network



شکل (۴): نمودار میزان خطا برحسب سطح گسترش و تعداد نرون
Fig. (4): Error versus spread level and neurons

با استفاده از این نتایج و بررسی نقاط کمینه مقادیر زیر برای شبکه بهینه مدار شعاعی، انتخاب می‌شود. بنابراین، بهترین نتیجه با استفاده از پارامترهای بیان شده در جدول (۲) به دست می‌آید.

Table (2): Optimal parameters for VSA

جدول (۲): ترکیب بهینه پارامترهای سیستم تخمین حد پایداری ولتاژ

Parameter	Quantity
Spread	9
Number of RBF function	150
Goal	0
Number of data set	164

۲-۴- مدل‌های بهینه

برای یافتن شبکه عصبی با توپولوژی مناسب، از معیار خطای مربعات میانگین استفاده می‌شود. در جدول (۱)، مدل‌های بهینه در تخمین حد پایداری استاتیکی ولتاژ بیان شده است.

Table (1): Optimal models of VSA estimation

جدول (۱): مدل‌های بهینه سیستم تخمین حد پایداری استاتیکی ولتاژ

Model	MSE	Goal	Spread	neurons
1	107.319	0	11	25
2	30.5	0	12	50
3	12.56	0	12	75
4	3.049	0	10	100
5	0.219	0	11	125
6	0.0039	0	9	150

۵- پیش‌بینی وضعیت استاتیکی پایداری ولتاژ

یکی از مهم‌ترین معیارهایی که در تمامی شبکه‌های انتقال مورد توجه برنامه‌ریزان و بهره‌برداران قرار می‌گیرد، وضعیت شبکه از دیدگاه ولتاژی است. پیش‌بینی وضعیت استاتیکی پایداری ولتاژ، بخش مهمی از ادبیات مرتبط با مطالعه سیستم قدرت را تشکیل می‌دهد و بسیاری از تجربه‌های علمی در زمینه بهره‌برداری از شبکه را به خود اختصاص داده است [۱۱].

۶- شبکه عصبی PNN

شبکه PNN یک ساختار عصبی قابل انعطاف و نوع خاصی از شبکه RBF است که به خاطر داشتن لایه رقابتی برای مسایل طبقه‌بندی مناسب می‌باشد [۱۷]. اصول و مبانی شبکه PNN در سال ۱۹۶۶ میلادی توسط اسپچ پایه‌گذاری گردید. توضیحات تکمیلی در خصوص شبکه PNN در ضمیمه الف آمده است.

۶-۱ معرفی ساختار شبکه PNN

این شبکه دارای دو لایه اصلی می‌باشد. یک لایه تابع بنیادی شعاعی (RBF) و یک لایه رقابتی است. ترانهاده ماتریس تشکیل شده از بردارهای ورودی به عنوان ماتریس وزن لایه اول و ماتریس تشکیل شده از بردارهای هدف به عنوان ماتریس وزن لایه دوم در نظر گرفته می‌شود. در حالت عملکردی نرمال، با ارائه یک بردار ورودی جدید به شبکه، فاصله آن بردار با تک تک بردارهای آموزشی در لایه اول محاسبه شده و برداری تشکیل می‌شود که مولفه‌های آن نشان‌دهنده میزان شباهت بردار ورودی جدید با بردارهای آموزشی لایه اول می‌باشد. با ورود این بردار به لایه دوم نرون‌های موجود در این لایه با هم رقابت کرده و برداری تولید می‌کند که هر مولفه آن نشان‌دهنده احتمال قرار گرفتن بردار ورودی جدید در هر یک از دسته‌ها یا طبقات برداری موجود است. شبکه به ازای بزرگترین مولفه این بردار عدد ۱ و به ازای سایر مولفه‌ها عدد صفر را جایگزین می‌کند. به این ترتیب دسته یا طبقه مربوط به بردار ورودی جدید تعیین می‌شود [۱۷].

۷- دسته‌بندی کننده SVM

ماشین بردار پشتیبان یک مجموعه از روش‌های یادگیری با ناظر است که برای طبقه‌بندی و رگرسیون استفاده می‌شود. ماشین بردار پشتیبان در سال ۱۹۹۲ توسط وینیک و چروننکیس بر پایه‌ی تئوری یادگیری آماری معرفی شد. اصل ماشین بردار پشتیبان یک موجودیت ریاضی است [۱۸].

SVM از یک ابر صفحه خطی تفکیک‌گر بهینه برای دسته‌بندی داده‌ها استفاده می‌کند که این ابر صفحه بهینه از حداکثر کردن حاشیه بدست می‌آید. به این منظور باید یک مساله بهینه‌سازی غیرخطی مقید حل شود. SVM جزو گروه دسته‌بندی کننده‌هایی است که بدون دانستن مدل توزیع داده‌ها دسته‌بندی را انجام می‌دهد. حتی فراتر، این مدل

نیازی به دانستن یک ساختار کلی از مساله ندارد. به طور کلی SVM بردارهای ورودی را با استفاده از یک تابع کرنل به یک فضای بزرگتری می‌برد که تفکیک‌پذیری خطی در آن بهتر و قاطعانه‌تر انجام شود [۱۸]. تعدادی داده‌ی آموزشی وجود دارد. یک مجموعه از نقاط به فرم:

$$D = \{(x_i, y_i)\} \quad x_i \in \mathbb{R}^p, y_i \in \{1, -1\} \quad (2)$$

$$i = 1, \dots, n$$

که y_i می‌تواند ۱ یا -۱ باشد، که مشخص‌کننده تعلق x_i به کلاس مورد نظر است. هر x_i یک بردار p بُعدی است. هدف پیدا کردن جداکننده ماکزیمم حاشیه‌ای می‌باشد، به طوری که نقاط y_i برابر با ۱ را از نقاط -۱ جدا می‌کند. هر ابرصفحه می‌تواند به صورت یک مجموعه از نقاط x نوشته شود که رابطه‌ی زیر معرف آن است:

$$W \cdot X - b = 0 \quad (3)$$

بردار w بردار نرمال ابرصفحه است که بر آن عمود می‌باشد. پارامتر b ، میزان آفست ابرصفحه از مبدا، در امتداد بردار نرمال w می‌باشد.

هدف انتخاب w و b می‌باشد به طوری که حاشیه یا فاصله‌ی بین ابرصفحه‌های موازی ماکزیمم شود تا جداسازی داده‌ها تسهیل گردد. فاصله بین دو ابرصفحه (پهنای حاشیه)، برابر $\frac{2}{\|w\|}$ است، بنابراین لازم است $\|w\|$ مینیمم گردد. ضمن اینکه، از قرار گرفتن نقاط در حاشیه جلوگیری می‌شود.

و با اضافه کردن محدودیت:

$$y_i (w \cdot x_i + b) \geq 1 \quad (4)$$

به همراه ضرایب لاگرانژ غیرمنفی، مسئله بهینه‌سازی به صورت زیر بیان می‌شود.

$$(\bar{w}, b, \alpha) = \frac{1}{2} \|w\|^2 \quad (5)$$

$$- \sum_{i=1}^N \alpha_i [y_i (\bar{w}^T x_i + b) - 1]$$

حال لازم است (w, b, α) ، نسبت به w و b مینیمم شود.

با استفاده از رابطه‌ی $\|w\|^2 = w \cdot w$ و جایگزینی

$$w = \sum_{i=1}^N \alpha_i y_i x_i \quad \text{و} \quad \sum_{i=1}^N \alpha_i y_i = 0$$

مسئله بهینه‌سازی SVM به دست آمده، مسئله‌ی بهینه‌سازی ماکزیمم

کردن (\bar{w}, b, α) نسبت به α_i را حل می‌کنیم:

$$L(\bar{w}, b, \alpha) = \frac{1}{2} \|w\|^2 \quad (6)$$

$$- \sum_{i=1}^N \alpha_i [y_i (\bar{w}^T x_i + b) - 1]$$

$$= \frac{1}{2} \bar{w}^T \bar{w} - \sum_{i=1}^N \alpha_i \bar{w}^T x_i y_i - b \sum_{i=1}^N \alpha_i y_i + \sum_{i=1}^N \alpha_i$$

تنها تعداد کمی از α_i ها می‌توانند بزرگ‌تر از صفر باشند، که این تعداد دقیقاً بردارهای پشتیبان x_i هستند، که روی حاشیه قرار دارند و در رابطه‌ی $y_i (w \cdot x_i + b) \geq 1$ صدق می‌کنند.

شده در این بخش سیستم استاندارد ۱۴ باسه IEEE می باشد که با نرم افزار Digsilent شبیه سازی شده است.

افزایش بار شبکه روی ۶ باس بار انجام گرفته است. بار پایه این ۶ باس، ۱۰ درصد در هر مرحله افزایش یافته و برای هر باس بار یک منحنی توزیع نرمال با میانگین بار پایه همان باس و انحراف معیار ۰/۳ در نظر گرفته شده است. در هر مرحله افزایش بار پایه یک باس بار، ۲۰ نمونه تصادفی از منحنی توزیع نرمال آن بار گرفته شده است. بار با ضریب توان ثابت بوده و افزایش بار به معنی افزایش توان ظاهری است. V و δ به ترتیب، اندازه و زاویه ولتاژ هر باس می باشد.

- ورودی: $[S, V, \delta]$

- خروجی: شاخص L

$$\text{Indicator } L_j = \left| 1 + \frac{\dot{V}_{oj}}{\dot{V}_j} \right| = \left| \frac{\dot{S}'_j}{V_j^2 \dot{Y}'_{jj}} \right| = \frac{S'_j}{V_j^2 Y_{jj}} \quad (9)$$

ماشین بردار پشتیبان (SVM) و شبکه عصبی PNN، در خروجی، دو کلاس را نشان می دهند.

کلاس ۱: سیستم پایدار به ازای $L < 0.9$

کلاس ۲: سیستم ناپایدار به ازای $L > 0.9$

تعداد ۳۰۰ داده برای آموزش استفاده شده و ۷۴ داده برای مرحله تست انتخاب شده است.

داده های تست کاملا متفاوت از داده های آموزش انتخاب شده است. داده های آموزش ناشی از افزایش بار شبکه به دست آمده اما داده های تست ناشی از حذف برخی از خطوط در بارگذاری های مختلف (به خصوص در بارگذاری حداکثر)، و حذف برخی از منابع توان راکتیو در بارگذاری حداکثر، می باشد.

اهمیت سیستم ارائه شده به این است که داده های تست کاملا متفاوت از داده های آموزشی انتخاب شده اند. انعطاف پذیری بالا و خطای تعمیم کم، از ویژگی های سیستم پیشنهادی است.

۹-۱- نتایج حاصل از شبکه عصبی PNN

با توجه به مطالب گفته شده، در نتایج حاصل از سیستم تشخیص پایداری با استفاده از شبکه عصبی PNN، بهترین مدل به دست آمده با انحراف گوسی ۱۰ و $MSE = 0/0.946$ می باشد، که در این مدل به ۶۷ نمونه از ۷۴ داده ی تست، پاسخ درست داده است.

۹-۲- نتایج حاصل از SVM

در این مقاله از سه نوع کرنل گوسی، چندجمله ای و خطی استفاده شده است. مقادیر پارامترهای γ و C با استفاده از روش آزمون و خطا به دست آمده است. مشاهده می شود کارایی کرنل گوسی بیش از کرنل های دیگر است. با بررسی دو تابع کرنل شعاعی و چندجمله ای درجه ۳ و با تغییر پارامترهای SVM، بهترین مدل ها طبق جدول (۳) به دست آمده است.

اگر داده ی آموزشی به صورت خطی قابل جداسازی نباشد، با اضافه کردن متغیر کمکی^۸ می توان جداسازی اشتباه را در نمونه های نویزی تصحیح کرد.

رابطه جدید شامل متغیرهای کمکی به صورت زیر می باشد:

$$\phi(\vec{w}, \xi) = \frac{1}{2} \|\vec{w}\|^2 + c \sum_{i=1}^N \xi_i \quad (7)$$

با در نظر گرفتن محدودیت زیر:

$$y_i (w \cdot x_i + b) \geq 1 - \xi_i \quad (8)$$

عبارت $c \sum_{i=1}^N \xi_i$ حداکثر تعداد خطا را تعیین می کند.

پارامتر c ، به عنوان راهی برای کنترل سرریز است. هرچه c بزرگتر باشد، حساسیت بیشتری نسبت به خطاهای رخ داده پیدا می کند. در حقیقت c یک مصالحه^۹ بین پهنای حاشیه و جداسازی اشتباه است. به c پارامتر تنظیم کننده^۸ گفته می شود و باید توسط کاربر انتخاب شود.

اگر مجموعه داده را نتوان به سادگی با یک خط دسته بندی نمود، از نگاشت به فضایی با ابعاد بالاتر استفاده می شود. فضای نگاشت اصلی همواره می تواند به فضای ویژگی با ابعاد بالاتر دیگری، که مجموعه آموزشی قابل جداسازی باشد، نگاشت یابد. به دلیل ابعاد بیشتر فضای ویژگی، محاسبات پیچیده تر می شود. در حالت کلی، این فضا بی نهایت است. برای غلبه بر این مشکل از ترفند کرنل^۹ استفاده می شود [۱۸].

۸- ارزیابی شاخص L در پیش بینی فروپاشی ولتاژ

شاخصی که برای پیش بینی پایداری ولتاژ در مراجع [۹، ۱۴] ارائه گردیده، در این بخش مورد بررسی قرار می گیرد. این شاخص بر اساس اطلاعات پخش بار و قوانین کیرشهف به دست می آید [۱۴]. شاخص مورد مطالعه، مسئله ناپایداری ولتاژ را با دقت قابل قبولی پیش بینی می نماید.

شاخص L مقداری بین ۰ تا ۱ را دارا می باشد. از این رو برای سیستمی با پایداری ولتاژ بالا، باید این شاخص کمتر از واحد باشد. مقدار شاخص L ، فاصله سیستم تا فروپاشی ولتاژ را نشان می دهد. این شاخص نشان دهنده حاشیه پایداری است، که برای هر سیستم پایدار، مقدار آن باید از مقدار آستانه تعیین شده کمتر باشد. این مقدار آستانه به مشخصات و سیاست های مدیریتی سیستم قدرت وابسته است [۹]. این شاخص به دلیل سادگی و حجم محاسبات پایین مورد توجه قرار گرفته است و بر مبنای پاسخ پخش بار ساده محاسبه می شود. مقدار L در یک مسیر دایره ای از مقدار صفر در شرایط بی باری تا مقدار یک در شرایط بار زیاد، امکان پذیر است [۱۴].

۹- شبیه سازی و تولید داده

مقادیر توان ظاهری، اندازه ولتاژ و زاویه ولتاژ هر باس بار شبکه، به عنوان مولفه های ورودی در نظر گرفته شده است. شاخص L به عنوان شاخصی که با تقریب خوبی نقطه فروپاشی استاتیکی ولتاژ را نشان می دهد به عنوان مولفه خروجی بیان شده است [۱۴]. شبکه استفاده

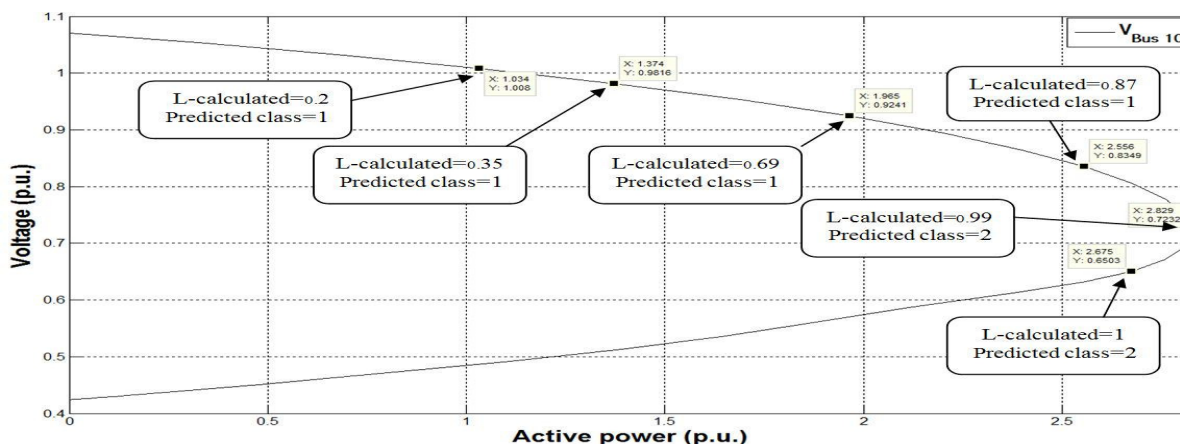
بر طبق جدول (۳)، تغییرات پارامتر تنظیم نسبت به میانگین مرتب‌ت‌ها، خطا، مستقیم و تقریباً خطی می‌باشد. نتیجه اینکه هر چه مقدار متغیر C افزایش یابد اهمیت میزان خطا بیشتر بوده و میزان حاشیه کاهش می‌یابد و خطای تعمیم افزایش می‌یابد. با افزایش این پارامتر زمان تجزیه تحلیل SVM نیز بیشتر می‌شود. در جدول (۳) مشاهده می‌شود که با تابع چندجمله‌ای، SVM زمان کمتری نسبت به تابع شعاعی خواهد داشت.

برای درک بهتر و اثبات عملکرد سیستم هوشمند پیشنهادی، داده‌های واقعی و پیش‌بینی شده مبتنی بر روش پیشنهادی در شرایط تست بر روی یک نمودار آورده شده است. همان طور که در منحنی P-V شکل (۵) نشان داده شده است، در شرایط مختلف بار گذاری و با توجه به شاخص L محاسبه شده از داده‌های واقعی، سیستم پیش‌بینی پیشنهادی قابلیت تخمین درست وضعیت ولتاژ سیستم را دارا می‌باشد. همچنین با دقت در منحنی P-V شکل (۶) مشهود است که در شرایط مختلف بارگذاری و با توجه به شاخص VSM محاسبه شده از داده‌های واقعی، سیستم هوشمند پیشنهادی قابلیت رگرسیون قابل قبولی را دارا می‌باشد.

Table (3): Optimal SVMs for voltage collapse forecasting
جدول (۳): مدل‌های بهینه SVM برای پیش‌بینی فروپاشی ولتاژ

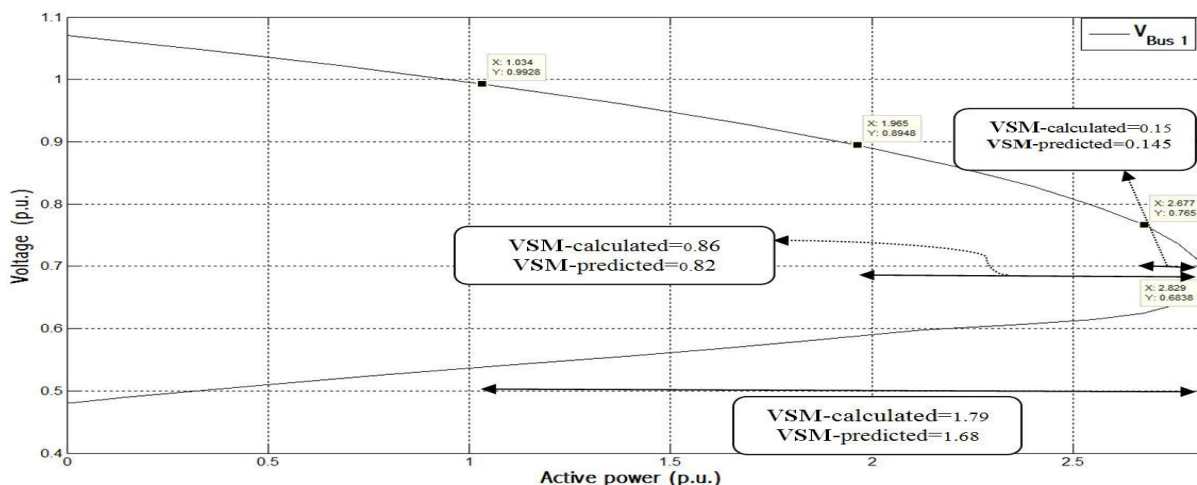
Kernel	Model	C	γ	Time	MSE	SV
RBF	1	10	1	25.6	0.001	2
	2	10	5	25.9	0.001	4
	3	10	10	25.7	0.001	7
	4	100	5	27.2	0.01	2
	5	1000	9	28.8	0.1	2
	6	10000	10	30.9	1	2
Poly	7	10	0.02	25.2	0.001	3
	8	100	0.002	26.7	0.01	2

تعداد بردارهای پشتیبان به انتخاب کرنل بستگی دارد. سیستمی که تعداد بردار پشتیبان کمتری می‌گیرد، عملکرد بهتری دارد. مقدار γ (گاما) باید طوری انتخاب شود که کمترین تعداد بردارهای پشتیبان در SVM به کار گرفته شود. هر چه تعداد بردارهای پشتیبان کمتر باشد کیفیت و نتیجه‌گیری بالاتر است. با توجه به محاسبات انجام شده، تابع RBF با $C=10$ و $\gamma=1$ ، با تعداد بردارهای پشتیبان «۲» بهترین مدل را نتیجه می‌دهد.



شکل (۵): نمودار P-V باس ۱۰ شبکه IEEE همراه با مقادیر واقعی شاخص L و تعیین وضعیت پایداری از روش طبقه بندی هوشمند پیشنهادی (SVM) در شرایط مختلف بار گذاری

Fig. (5): P-V curve for bus No. 10 (IEEE test case) together real L index & VSA using proposed intelligent method (SVM)



شکل (۶): نمودار P-V باس ۱ شبکه یزد همراه با مقادیر واقعی محاسبه شده و مقادیر به دست آمده از روش رگرسیون هوشمند پیشنهادی در شرایط مختلف بار گذاری

Fig. (6): P-V curve for bus No. 1 (Yazd network) together calculated & predicted VSM in different loading states

بعلاوه، با پارامترهای به دست آمده از ابزار پیش‌بینی می‌توان حتی در شرایط کمی متفاوت با ویژگی‌های موجود، طبقه‌بندی مناسبی انجام داد. اهمیت روش‌های به کار رفته در این مقاله سرعت بالای آنها در آموزش و طبقه‌بندی، نسبت به دیگر روش‌های شبکه عصبی می‌باشد. ماشین بردار پشتیبان، در طبقه‌بندی مواردی که انتخاب و استخراج ویژگی غیر ممکن است روش بسیار مناسبی است و اگر داده‌ها دارای نویز باشند مشکل overfitting آن کمتر از شبکه‌های عصبی می‌باشد.

پی‌نوشت:

- 1- Voltage Stability Margin
- 2- Radial Basis Function
- 3- Multi- Layer Perceptron
- 4- Supported Vector Machine
- 5- Probabilistic Neural Network
- 6- Slack Variables
- 7- Trade - Off
- 8- Regularization
- 9- Kernel trick

۱۰- نتیجه‌گیری

پایداری سیستم‌های قدرت، از دهه دوم قرن بیستم تاکنون به عنوان یک مسئله مهم مطرح بوده است. در این مقاله سعی شده است که پایداری سیستم قدرت از نظر ولتاژ با ابزار یادگیری ماشین بررسی و پیش‌بینی شود. بخش اول پژوهش حاضر، به تخمین حاشیه پایداری استاتیکی ولتاژ می‌پردازد. مزیت روش پیشنهادی، دقت بالای آن در نشان دادن حاشیه پایداری ولتاژ نواحی بار شبکه، همزمان با بهره برداری از شبکه می‌باشد. با توجه به عملکرد ناحیه‌ای روش پیشنهادی، درک درست و ساده‌ای از وضعیت پایداری ولتاژ در نواحی مختلف بار را نشان می‌دهد که به بهره‌برداری از شبکه در حاشیه ولتاژ مناسب کمک می‌کند.

در بخش دوم، پیش‌بینی پایداری ولتاژ، به کمک ابزار مشهور تشخیص الگو، بیان شده است. در پیش‌بینی پایداری ولتاژ از حیث خطا، SVM نسبت به PNN بهتر عمل می‌کند، همچنین از نظر کاهش تعداد نمونه‌های آموزشی و زمان آموزش سیستم تشخیص برتری دارد.

References

- [1] P. Kundur, "Power system voltage stability and control", Mc-Graw Hill, New York, 1994.
- [2] S. Chakrabarti, "Voltage stability monitoring by artificial neural network using a regression-based feature selection method", Expert Sys. with Appl., 35, 1802-1808, 2008.
- [3] F. Zhihong, et.al., "The static voltage stability analysis methods for many generators power system - singularity decoupled method", Proceedings of CSEE, 12(3), pp. 10-18, 1992.
- [4] F. Zhihong, et.al., "The Static Voltage Stability Eigenvalue Analysis Method for Many Generators Power System", Jou. of Tsinghua Univ., 31(4), pp. 19-27, 1991.
- [5] V. Ajjarapu, C. Christy, "The continuation power flow: A tool for steady-state voltage stability analysis", IEEE Trans. on PWRs, Vol. 7, No. 1, pp. 416-423, 1992.
- [6] M.R. Aghamohammadi, S. Hashemi, M.S. Ghazizadeh, "Improving voltage stability margin using voltage profile and sensitivity analysis by neural network", Iranian Jou. of Elec. and Elec. Eng., Vol. 7, No. 1, pp. 33-41, 2011.

[7] J.A. Momoh, W. Zheng, K.D'Arnaud, "Fuzzy logic control application to enhance voltage stability of the electric power systems", IEEE/ISAP, pp. 1-6, Curitiba, Nov. 2009.

[8] M.A. Ríos, C.J. Zapata, O. Gómez, e.J.L. Sánchez, "Voltage stability assessment with ranking of contingencies using QV sensibility", IEEE Latin America Trans., Vol. 7, pp. 665-672, 2009.

[9] W. Nakawiro, E. Erlich, "Online voltage stability monitoring using artificial neural network", DRPT, Nanjing China, 978-7-900714-13-8/08/, 2008.

[10] C.A. Belhadji, H. Al-Duwaish, M.H. Shwehdi, A.S. Farag, "Voltage stability estimation and prediction using neural network", IEEE/ICPST, Vol. 2, pp. 1464-1467, Aug. 1998.

[11] L.D. Arya, L.S. Titare, D.P. Kothari, "Determination of probabilistic risk of voltage collapse using radial basis function (RBF) network", Elec. Pow. Sys. Res., Vol. 76, pp. 426-434, 2006.

[12] M. Nizam, A. Mohamed, M. Al-Dabbagh, A. Hussain, "Using support vector machine for prediction dynamic voltage collapse in an actual power system", Int. Jou. of Elec. and Elec. Eng., Vol. 3, No. 10, 2009.

[13] V. Balamourougan, T.S. Sidhu, M.S. Sachadev, "Technique for online prediction of voltage collapse", IEE Proc. of the Gen., Tran. and Dist., Vol. 151, pp. 453-460, 2004.

[14] A.M. Mahmoud, S.K. Shelli, "Real time voltage collapse prediction using artificial neural network", WCECS, Vol I, USA, Oct. 2009.

[15] N. Amjady, M.H. Velayati, "Evaluation of hopf bifurcation considering the effect of load models and excitation system parameters", Int. Rev. of Elec. Eng. (IREE), Vol. 6, No. 5, pp. 2419-2427, 2011.

[16] N. Amjady, M.H. Velayati, "Dynamic voltage stability prediction of power systems by a new feature selection technique and probabilistic neural network", Euro. Trans. Elec. Pow. (ETEP), Vol. 21, No. 1, pp. 312-328, 2011.


[17] N.I.A. Wahab, A. Mohamed, A. Hussain, "Fast transient stability assessment of large power system using probabilistic neural network with feature reduction techniques", Expert Sys. with Appl., 38, pp. 11112-11119, 2011.

[18] V.N. Vapnik, "Statistical Learning Theory", John Wiley, New York, 1998.

در سال ۱۹۹۰ میلادی نشان دادند که تابع نمایی جزء گروهی از توابع است که دارای بهترین خواص در تقریب سازی هستند. منظور از سطح گسترش، انحراف استاندارد منحنی گوسی (σ) است. تابع بنیادی شعاعی (RBF)، تابعی به شکل زیر می باشد.

$$\phi(\|x - u_j\|) = \exp(-\|x - u_j\| / \sigma_j) \quad (\text{الف-۲})$$

این تابع، مانند منحنی توزیع استاندارد آماری است. می توان u را میانه و σ را انحراف استاندارد منحنی (سطح گسترش) در نظر گرفت. به عبارت دیگر σ فاکتور عرض کرنل نام می باشد.



شکل (الف-۲): منحنی نمایش تابع پاسخ یا تابع انتقال (تحریک) نرون شعاع با یک ورودی

Fig. (A-2): Response curve for single input RBF
اگر دو متغیر ورودی داشته باشیم، در این حالت تابع بنیادی شعاعی به یک تابع دو متغیره تبدیل می شود.



شکل (الف-۳): منحنی نمایش تابع پاسخ یا تابع انتقال (تحریک) نرون شعاع با دو ورودی


Fig. (A-3): Response curve for double input RBF

ضمیمه الف: شبکه عصبی شعاعی و احتمالاتی ساختار شبکه عصبی شعاعی

این شبکه متشکل از سه لایه است. لایه اول لایه ورودی، که در آن هیچ پردازشی صورت نمی گیرد. لایه دوم یا لایه پنهان، یک انطباقی غیرخطی مابین فضای ورودی و فضای بعد آن برقرار می کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک پذیر غیرخطی دارد [۱۱]. سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می کند. تابع لایه پنهان دارای رابطه ای مطابق رابطه زیر است:

$$F(x) = \sum_{j=1}^p w_j \phi(\|x - u_j\|) \quad (\text{الف-۱})$$

تعداد کل نرون های لایه پنهان p و w_j اتصال سیناپسی نرون ها است. بردار u را مرکز گوسی می نامیم و x بردار ورودی می باشد. تابع کرنل ϕ ، به عنوان تابع پاسخ نرون در نظر گرفته می شود.




شکل (الف-۱): ساختار شبکه عصبی شعاعی مداری (RBF)

Fig. (A-1): RBF construction

دلیل انتخاب تابع نمایی گوسی (تابع کرنل) به عنوان تابع پاسخ نرون ها در شبکه های با تابع شعاع مداری این است که ژبروسی و پوگی

شبکه عصبی احتمالاتی (PNN)

اصول و مبانی شبکه PNN در سال ۱۹۶۶ میلادی توسط اسپچ پایه گذاری گردید. این شبکه دارای سه لایه کلی می باشد: لایه اول لایه ورودی، لایه دوم یک لایه تابع بنیادی شعاعی (RBF) و لایه سوم آن یک لایه رقابتی همراه با مرحله تصمیم گیری است. مجموعه آموزشی شبکه PNN دارای حالت خاصی است با این که هیچ محدودیتی در مورد مولفه های بردارهای ورودی وجود ندارد اما در بردارهای هدف یکی از مولفه های دارای مقدار ۱ و بقیه صفر هستند. بنابراین بردارهای هدف به تعداد مولفه هایشان کلاسها یا طبقاتی را نشان می دهند که هر یک از بردارهای ورودی می توانند به آن وابسته شوند. ساختار این شبکه در شکل زیر نشان داده شده است.



شکل (الف-۴): شبکه عصبی احتمالی
Fig. (A-4): PNN construction

معرفی شبکه عصبی PNN

از نگاهی دیگر، شبکه عصبی PNN از نوع شبکه های feed forward می باشد که دارای ۴ لایه است. در PNN تعداد نوروں های لایه ورودی با تعداد ورودی های انتخاب شده برابر است. تعداد گره های لایه های پنهان نیز با تعداد داده های آموزش (NS) برابری می کند. لایه سوم در PNN دارای NC نوروں می باشد. در حقیقت تعداد کلاس های Z را بیان می کند. برای مسئله پایداری ولتاژ و ولتاژ NC=2 می باشد (زیرا اگر در سیستم پایداری دینامیکی برقرار نباشد (Z=2). برای پیش بینی وضعیت دینامیکی ولتاژ، j^{th} داده آموزش دارای الگوی مطابق با زیر است:

$$[y_{j1}, y_{j2}, \dots, y_{jm}, z_j] \quad 1 \leq j \leq NS \quad (الف-۳)$$

مکانیزم آموزش شبکه عصبی PNN:

در فاز آموزش شبکه عصبی، وزن اتصالی در PNN باید چنان تنظیم شوند که خطای آموزش شبکه مینیمم گردد. شبکه PNN دارای سه وزن (weight) می باشد و فرایند آموزش PNN با استفاده از این وزن ها صورت می گیرد:

$$\begin{aligned} W_{ji}^{(H)} &= y_{ji}, 1 \leq j \leq NS, 1 \leq i \leq m \\ W_{ji}^{(P)} &= 1 \text{ if } z_i = C_k, \\ &= 0 \text{ otherwise } 1 \leq k \leq NC, 1 \leq j \leq NS \\ W_{ji}^{(D)} &= 1, 1 \leq k \leq NC \end{aligned}$$

$W_{ji}^{(H)}$ ، وزن ارتباطی میان i^{th} نرون در لایه ورودی و j^{th} گره در لایه پنهان را نشان می دهد. $W_{ji}^{(P)}$ ، وزن ارتباطی میان j^{th} نرون در لایه پنهان و k^{th} گره در لایه سوم را نشان می دهد. حال چنانچه j^{th} داده آموزش متعلق به k^{th} کلاس باشد، در این صورت وزن ارتباطی میان j^{th} گره در لایه پنهان و k^{th} نرون در لایه سوم برابر با ۱ خواهد شد. در غیر این صورت برابر با صفر است. $W_{ji}^{(D)}$ ، وزن ارتباطی میان لایه سوم و چهارم می باشد.

مکانیزم تست شبکه عصبی PNN

n^{th} داده تست را می توان به فرم زیر نشان داد که این مجموعه تنها شامل داده های ورودی می باشد.

$$[y_{n1}, y_{n1}, \dots, y_{n1}] \quad (الف-۵)$$

خروجی داده های تست با استفاده از شبکه PNN که مورد آموزش قرار گرفته و وزن های آن با استفاده از روابط ذکر شده (الف-۴) تعیین شده است، به دست می آید. در نتیجه قابلیت PNN در درستی دسته بندی داده های تست نمایان خواهد شد. لازم به ذکر است که در آنالیزهای انجام شده در این مقاله، داده های تست به کار گرفته شده کاملاً متفاوت از داده های آموزش به کار گرفته شده برای آموزش شبکه عصبی می باشد.

زمانیکه n^{th} داده تست به PNN اعمال می شود، خروجی لایه پنهان مطابق با رابطه (الف-۶) خواهد بود:

$$f_{jn} = \exp \left(- \frac{\sum_{i=1}^m (W_{ji}^{(H)} - y_{ni})^2}{2\sigma_j^2} \right), \quad (الف-۶)$$

$$1 \leq j \leq NS, 1 \leq n \leq NT$$

به طوری که؛ f_{jn} بیان گر خروجی j^{th} نرون در لایه پنهان در پاسخ به n^{th} داده تست می باشد. همچنین NT تعداد داده های تست را نشان می دهد. بنابراین، بر اساس رابطه (الف-۶) ملاحظه می شود که f_{jn} یک تابع گوسی می باشد. به علاوه σ تنها پارامتر قابل تغییر در PNN می باشد. اما برای کم کردن تعداد پارامترهای قابل تغییر در PNN، این پروژه برای تمام توابع (مطابق با رابطه (الف-۶))، یک پارامتر در نظر گرفته شده است:

$$\sigma_j = \sigma, \quad 1 \leq j \leq NS \quad (الف-۷)$$

به پارامتر اخیر (σ) سطح گسترش گفته می شود. پاسخ k^{th} نرون در لایه سوم به n^{th} داده تست را می توان مطابق با رابطه زیر بیان نشان داد:

$$g_{kn} = \frac{\sum_{j=1}^{NS} W_{k,j}^{(P)} \cdot f_{jn}}{\sum_{j=1}^{NS} W_{k,j}^{(P)}}, \quad 1 \leq k \leq NC, \quad (الف-۸)$$

$$1 \leq n \leq NT$$

در رابطه بالا، g_{kn} یک مقدار متوسط از میزان نزدیکی n^{th} داده تست به کلاس k را می دهد. در لایه چهارم کلاس برنده برای داده تست بر اساس بیشترین مقدار g_{kn} تعیین می گردد.

بردارهای مرجع، سطر ماتریس w را می‌سازند. بنابراین بردار n فاصله بین بردار ورودی مفروض P و بردارهای مرجع را محاسبه می‌کند. اگر فرض کنیم الگوها با طول واحد نرمالیزه شده باشند، آنگاه ورودی خالص n_i با کسینوس زاویه بین بردار P و بردار مرجع i برابر خواهد بود. این زاویه را با θ_i نشان می‌دهیم. در این صورت:

$$n = WP = \begin{bmatrix} W_1 \\ \vdots \\ W_s \end{bmatrix} P = \begin{bmatrix} W_1 P \\ \vdots \\ W_s P \end{bmatrix} = \begin{bmatrix} \cos \theta_1 \\ \vdots \\ \cos \theta_s \end{bmatrix} \quad (10-الف)$$

تابع تبدیل comp مقدار خروجی (۱) را به سلولی نسبت خواهد داد که بردار وزنش کمترین زاویه را و یا به عبارتی کوچکترین فاصله را با بردار ورودی داشته باشد. توجه داریم که در اینجا w_i سطر i ام ماتریس W را نشان می‌دهد.

یادگیری رقابتی

اکنون به دنبال یک قانون یادگیری هستیم که بتواند برای آموزش ماتریس وزن در شبکه رقابتی مورد استفاده قرار گیرد. هنگامی که صحبت از قانون یادگیری می‌کنیم، توجه داریم که به الگوهای مرجع دسترسی نداریم، چون در غیر این صورت عملاً نیازی به قانون یادگیری نداریم. چنین نحوه یادگیری به قانون یادگیری اینستار معروف است.

$$W_i(k) = W_i(k-1) + a a_i(k) [P^T(k) - W_i(k-1)] \quad (11-الف)$$


که در آن w_i سطر i ام ماتریس w است. اما برای لایه رقابتی تنها a_i^* مربوط به سلول برنده غیرصفر است، پس:

$$W_{i^*}(k) = (1-a) W_{i^*}(k-1) + a P^T(k) \quad (12-الف)$$

برای دیگر سلول‌ها بردار وزن تغییر نمی‌کند:

$$W_i(k) = W_i(k-1) \quad i \neq i^* \quad (13-الف)$$

لذا سطری از ماتریس وزن w که بیشترین نزدیکی را با بردار ورودی P دارد (مثلاً بزرگترین ضرب داخلی یا کمترین فاصله را با بردار ورودی دارد) به سمت بردار ورودی حرکت می‌کند. این حرکت در مسیری قرار دارد که بردار وزن قدیمی را به بردار ورودی مطابق شکل زیر وصل می‌کند.



شکل: (الف-۶) نحوه بروزرسانی بردار وزن
Fig. (A-6): Weighting vector updating

h_n بیانگر خروجی تنها نرون لایه چهار در پاسخ به n^{th} داده تست می‌باشد:

$$h_n = q |1 \leq n \leq NC, \text{ and } g_{an} = \max_k (g_{kn}) \quad (9-الف)$$


به عبارت بهتر، h_n خروجی نهایی PNN در پاسخ به n^{th} داده تست می‌باشد.

لایه رقابتی

در لایه رقابتی هر سلول میزان خروجی خود را تقویت و میزان خروجی دیگر سلول‌ها را تضعیف می‌کند. بدین ترتیب مکانیزم یادگیری رقابتی رخ می‌دهد. هر قانون یادگیری رقابتی دارای سه مولفه عمومی زیر می‌باشد.

- ۱- مجموعه سلول‌های که به یک مجموعه از ورودیها، پاسخ‌های مختلف می‌دهند. مثلاً هر سلول به یک دسته از ورودی‌ها پاسخ می‌دهد. این ویژگی ناشی از توزیع تصادفی وزن‌های سلول است. لذا سلول‌ها یاد می‌گیرند تا نقش ردیاب یا جستجوگر مشخصه را به عهده بگیرند.
- ۲- مکانیسمی که فرصت رقابت را در اختیار سلول قرار می‌دهد، این فرصت تمایز یک سلول (سلول برنده) از دیگر سلول‌ها را فراهم می‌کند.
- ۳- وجود یک حد اشباع روی خروجی هر سلول.

عموماً فعال بودن هر نرون توسط سطح تحریک معین می‌شود و فرض می‌شود که سطح تحریک نرون i ام، n_i تابعی نزولی از فاصله بین بردار وزن سلول و بردار محرک ورودی P است. یک نرون را فعال گویند اگر سطح فعالیتش از یک مقدار آستانه بیشتر باشد. در یادگیری رقابتی بین سلول‌ها بر اساس سطح تحریک، رقابتی جهت یادگیری سریعتر صورت می‌گیرد. یک لایه رقابتی در شکل زیر نشان داده شده است. که در آن i^* شماره سلولی است که بیشترین n_i را دارد. تابع تبدیل COMP اندیس i^* را می‌یابد و سپس a_i^* را برابر یک، $a_i(i \neq i^*)$ را برابر صفر قرار می‌دهد.



شکل (الف-۵): لایه رقابتی
Fig. (A-5): Competition layer

$$a = \text{comp}(WP); a_i = \begin{cases} 1, & i = i^* \\ 0, & i \neq i^* \end{cases}$$

