



یک الگوی بهینه‌سازی شده بر پایه ANFIS برای تخمین آنلاین حد پایداری ولتاژ در شبکه‌های قدرت با استفاده از الگوریتم جدید SIOA و تکنیک کاهش ابعاد مبتنی بر حداقل مربعات جزئی

احسان اکبری^۱

^۱ دانشکده مهندسی برق و کامپیوتر، دانشگاه علوم و فنون مازندران، بابل، ایران e.akbari@ustmb.ac.ir

چکیده

این مقاله به چالش تخمین آنلاین حد پایداری ولتاژ (VSM) در شبکه‌های قدرت می‌پردازد. با توجه به نوسانات سریع در بار و شرایط عملیاتی متغیر، تخمین سریع و دقیق حد پایداری ولتاژ برای جلوگیری از رویدادهای ناپایداری ضروری است. با گسترش سیستم‌های قدرت، ابعاد داده‌های ورودی به طور قابل توجهی افزایش می‌یابد که نیاز به انتخاب ویژگی‌های کارآمد و تکنیک‌های کاهش ابعاد را ضروری می‌سازد. برای مقابله با این چالش، یک رویکرد هوشمند و هیبریدی نوآورانه پیشنهاد می‌شود که سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) را که توسط الگوریتم بهینه‌سازی Solifugae (SIOA) آموزش داده شده است، با رگرسیون حداقل مربعات جزئی (PLS) برای کاهش ابعاد و انتخاب ویژگی‌های غالب ترکیب می‌کند. مجموعه ویژگی اولیه شامل ویژگی‌های بار سیستم است که از واحدهای اندازه‌گیری فازوری (PMU) به دست می‌آید و اطلاعات اساسی درباره توپولوژی شبکه، سطوح بار، الگوهای تولید و رفتار سیستم کنترل را در برمی‌گیرد. اثربخشی چارچوب ANFIS-SIOA+PLS پیشنهادی با استفاده از سیستم‌های آزمایشی 39IEEE باس اعتبارسنجی شده است. تحلیل مقایسه‌ای با مدل‌های موجود در مقالات، عملکرد برتر روش پیشنهادی را به ویژه در زمینه کاهش ویژگی‌ها و سرعت همگرایی نشان می‌دهد. قابل توجه است که رویکرد پیشنهادی، کاهش ریشه میانگین مربعات خطا (RMSE) را به میزان 41.53٪ برای سیستم تست 39 باس نسبت به بهترین نتایج گزارش شده در ادبیات موجود به دست می‌آورد. این بهبود کارآمدی و پایداری روش پیشنهادی را تأیید می‌کند.

واژه‌های کلیدی: تخمین آنلاین حد پایداری ولتاژ، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، الگوریتم بهینه‌سازی Solifugae (SIOA)، رگرسیون حداقل مربعات جزئی (PLS).

1. مقدمه

با گسترش بازارهای برق بازسازی شده و پذیرش چارچوب‌های رقابتی، سیستم‌های تولید برق به طور فزاینده‌ای در نزدیکی مرزهای پایداری خود عمل می‌کنند. در نتیجه، حتی نوسانات یا خطاهای کوچک نیز می‌توانند منجر به ناپایداری سیستم شوند و باعث خسارات اقتصادی قابل توجهی از جمله قطعی برق و کاهش بار شوند [1]. علاوه بر این، ماهیت دینامیک سیستم‌های برق مدرن که تحت تأثیر تغییرات آنی بار، شرایط جوی متغیر و اختلالات ناگهانی قرار دارد، عدم قطعیت‌های قابل توجهی را معرفی می‌کند. این عوامل باعث می‌شود که تخمین آنلاین حد پایداری ولتاژ (VSM^1) هم چالش برانگیز و هم به اندازه کافی دقیق برای تصمیم‌گیری در زمان واقعی نباشد [2]. در نتیجه، نیاز روزافزون به ارزیابی دقیق و به موقع حد پایداری ولتاژ در سیستم‌های برق مدرن، محققان را بر آن داشته است تا روش‌های پیشرفته‌ای برای تخمین آنلاین توسعه دهند [3].

در [4]، یک رویکرد ارزیابی و نظارت آنلاین پایداری ولتاژ مبتنی بر تکنیک یادگیری ویژگی‌های بدون نظارت ارائه شده است. این روش داده‌کاوی که از چارچوب یادگیری احتمالی استفاده می‌کند، برای شناسایی و رتبه‌بندی ویژگی‌های پنهان در مجموعه داده‌های سیستم بر اساس توزیع احتمالی آن‌ها به کار رفته است، و ویژگی‌های بیشترین اطلاعات برای تحلیل انتخاب شده‌اند. یک روش داده‌محور دیگر، مدل (IRF^2)، در [5] پیشنهاد شده است که قابلیت‌های بهبود یافته‌ای در زمینه انتخاب ویژگی و طبقه‌بندی ارائه می‌دهد. در [6]، کنترل و پیش‌بینی حد پایداری ولتاژ با استفاده از رویکرد تحلیل حساسیت سنتی مورد بررسی قرار گرفته است. در این مطالعه، یک شاخص جدید تحت عنوان حد پایداری ولتاژ مبتنی بر روش تونن ($TVSM^3$) معرفی شده است که تحلیل حساسیت بر اساس آن انجام شده است. رویکرد مشابهی در [7] به کار رفته است که در آن روش شناسایی و کنترل ناپایداری ولتاژ مبتنی بر اندازه‌گیری‌های ولتاژ و جریان برای شناسایی مؤثرترین اقدامات کنترل پیشگیرانه علیه ناپایداری ولتاژ استفاده شده است. در [8]، نظارت آنلاین حد پایداری ولتاژ با استفاده از رویکرد ترکیبی مبتنی بر زیرفضای ویژگی‌ها انجام شده است که خروجی‌های مختلف از انتخاب‌کننده‌های ویژگی‌ها را برای بهبود عملکرد نسبت به روش‌های سنتی جمع می‌کند. با این حال، پیاده‌سازی این روش در سیستم‌های مقیاس بزرگ با تعداد زیادی باس چالش برانگیز بوده و بار محاسباتی قابل توجهی را به همراه داشته است. علاوه بر این، روشی برای ارزیابی آنلاین پایداری ولتاژ با استفاده از الگوریتم اصلاحی نیوتن در [9] پیشنهاد شده است که در آن فاصله‌های فروپاشی ولتاژ در زمان واقعی نسبت به نقطه پایه فروپاشی، بر اساس داده‌های تجهیزات اندازه‌گیری، به‌روزرسانی می‌شود. علیرغم دقت آن، این روش به زیرساخت اندازه‌گیری وسیع و پردازش حجم زیادی از داده‌ها نیاز دارد که محدودیت‌هایی در مقیاس‌پذیری ایجاد کرده است.

یک روش ارزیابی آنلاین پایداری ولتاژ مبتنی بر معادل تونن در [10] پیشنهاد شده است. شاخص پیشنهادی از حساسیت ولتاژ به توان در نقطه فروپاشی ولتاژ استنباط شده است. برای محاسبه این شاخص، داده‌های اندازه‌گیری شده از واحدهای اندازه‌گیری فازوری (PMU^4) لازم است. ارزیابی حد پایداری ولتاژ با استفاده از داده‌های PMU همچنین در [11]–[13] مورد بررسی قرار گرفته است. در [14]، ارزیابی لحظه‌ای پایداری ولتاژ کوتاه‌مدت با استفاده از یک شبکه عصبی هیبریدی مبتنی بر کانولوشن زمانی انجام شده است که قادر است پایداری سیستم را از روی مسیرهای ولتاژ پس از اختلال با دقت و کارایی بالا پیش‌بینی کند. با این حال، این روش نیاز به استفاده از مدل سیستم خاصی دارد و به در دسترس بودن حجم بالایی از داده‌ها برای پیاده‌سازی آن وابسته است.

¹ voltage stability margin

² Iterated Random Forest

³ Tevenan voltage stability margin

⁴ Phasor Measurement Units

در نتیجه، تقاضای روزافزونی برای روش‌های کارآمد که هم از لحاظ پیاده‌سازی آسان باشند به‌ویژه در محیط‌های شبکه مقیاس بزرگ و هم به اندازه کافی دقیق، وجود دارد. در این زمینه، ANFIS⁵ منطق فازی را با شبکه‌های عصبی ترکیب می‌کند و مدل‌هایی قابل تفسیر ارائه می‌دهد که به طور مؤثری بین دقت و مقیاس‌پذیری تعادل برقرار می‌کنند. این روش برای مدل‌سازی روابط پیچیده و غیرخطی با استفاده از داده‌های نسبتاً کوچک مناسب است و امکان گنجاندن تخصص انسانی از طریق قواعد فازی را فراهم می‌آورد. به دلیل قابلیت انطباق و توانایی‌های عمومی‌سازی قوی، ANFIS در محیط‌های دینامیک و نامشخص بسیار مؤثر است و اغلب از روش‌های سنتی یادگیری ماشین پیشی می‌گیرد [15]. با این حال، ANFIS نیاز به فرآیند آموزش دارد و روش‌های آموزش سنتی با محدودیت‌های متعددی مواجه هستند، از جمله نرخ‌های همگرایی کند، آسیب‌پذیری به مینیمم‌های محلی، و پیچیدگی محاسباتی قابل توجه به‌ویژه با افزایش ابعاد فضای ورودی [16]. برای رفع این مشکل، چندین مطالعه [17]، [18] از الگوریتم‌های تکاملی برای آموزش ANFIS استفاده کرده‌اند که موجب بهبود عملکرد و بهینه‌سازی پیکربندی آن می‌شود. این الگوریتم‌ها قابلیت‌های جستجوی سرتاسری ارائه می‌دهند و به پارامترهای اولیه حساسیت کمتری دارند، که امکان جستجوی مؤثرتر در فضای راه‌حل را فراهم می‌آورد. با استفاده از این رویکردهای ترکیبی، کارایی آموزش و دقت پیش‌بینی ANFIS به طور قابل توجهی بهبود می‌یابد و آن را به گزینه‌ای مقرون به‌صرفه‌تر برای کاربردهای آنی و مقیاس بزرگ تبدیل می‌کند [19]. در این مطالعه، یک الگوریتم بهینه‌سازی جدید الهام‌گرفته از طبیعت تحت عنوان الگوریتم بهینه‌سازی Solifugae (SIOA⁶) برای آموزش توابع عضویت سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) به کار رفته است. این الگوریتم نسبت به سایر تکنیک‌های بهینه‌سازی عملکرد بهتری از خود نشان می‌دهد و ویژگی‌های منحصر به فردی در مرحله جستجو دارد و سرعت بالایی در کاربردهای تخمین آنلاین ارائه می‌دهد. علاوه بر این، مدل رگرسیون حداقل مربعات جزئی (PLS⁷) برای کاهش ابعاد و استخراج ویژگی‌ها به عنوان یک روش بسیار مؤثر برای انتخاب ویژگی‌های غالب از مجموعه متغیرهای شبکه شناسایی شده است. این به دلیل یکپارچگی آن با رویکرد سنتی کاهش ویژگی‌های تحلیل مؤلفه‌های اساسی (PCA) و مزایایی همچون ارتباط مستقیم با پیش‌بینی، تفسیرپذیری، و انعطاف‌پذیری در مدل‌سازی است. عملکرد مدل تخمین پیشنهادی تحت شرایط مختلف عملیاتی سیستم‌های قدرت با استفاده از دو سیستم تست استاندارد ارزیابی شده و نتایج آن به طور کامل تحلیل می‌شود. همچنین، یک مطالعه مقایسه‌ای با سایر مدل‌های ارائه شده در ادبیات برای تأیید اثربخشی مدل پیشنهادی انجام می‌شود.

ادامه مقاله به شرح زیر سازمان‌دهی شده است: بخش 2 توضیحاتی جامع درباره سیستم استنتاج عصبی-فازی تطبیقی، الگوریتم بهینه‌سازی Solifugae، و تکنیک استخراج ویژگی حداقل مربعات جزئی ارائه می‌دهد. این بخش همچنین ساختار مدل پیشنهادی برای تخمین آنلاین حاشیه پایداری ولتاژ (VSM) را توضیح می‌دهد. در بخش 3، نتایج پیاده‌سازی مدل پیشنهادی بر روی سیستم 39 باسه IEEE ارائه شده و سپس مقایسه‌ای از نتایج به دست آمده انجام می‌شود. در نهایت، بخش 4 خلاصه‌ای از مطالعه و نتیجه‌گیری آن ارائه می‌دهد.

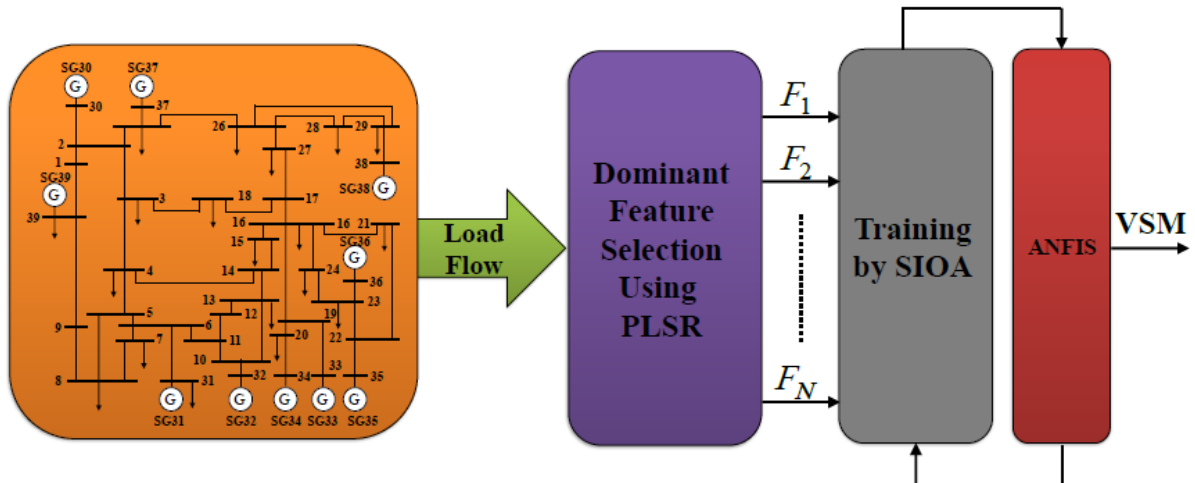
2. مدل پیشنهادی تخمین آنلاین حد پایداری ولتاژ

مدل کلی طرح تخمین آنلاین حد پایداری ولتاژ با استفاده از ANFIS-SIOA+PLSR پیشنهادی در شکل (1) نشان داده شده است.

⁵ Adaptive Neuro-Fuzzy Inference System

⁶ Solifugae-Inspired Optimization Algorithm

⁷ Partial Least Squares

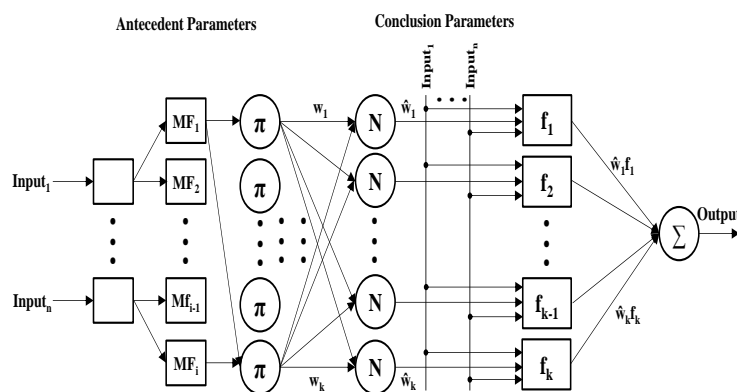


شکل 1- طرح تخمین آنلاین حد پایداری ولتاژ با استفاده از ANFIS-SIOA+PLSR

این ساختار از سه بلوک اصلی تشکیل شده است. بلوک اول نمایانگر پیکربندی سیستم قدرت مورد مطالعه است. بلوک دوم مربوط به ماژول استخراج ویژگی‌ها است که داده‌های پخش بار سیستم را به عنوان ورودی پردازش می‌کند. بلوک سوم شامل تخمین گر مبتنی بر ANFIS است که حد پایداری ولتاژ را با استفاده از ویژگی‌های انتخاب شده در بلوک دوم پیش‌بینی می‌کند. الگوریتم‌های بهینه‌سازی معمولاً برای آموزش مدل‌های ANFIS استفاده می‌شوند و در این مطالعه، الگوریتم بهینه‌سازی Solifugae برای این منظور به کار رفته است، زیرا از کارایی بالایی در تنظیم پارامترها و سرعت همگرایی برخوردار است. زیربخش‌های بعدی توضیحات دقیقی از تخمین گر ANFIS، الگوریتم پیشنهادی برای طراحی بهینه آن بر اساس SIOA و مدل کاهش ابعاد مبتنی بر $PLSR^A$ ارائه می‌دهند.

1-2- سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)

ساختار بلوک ANFIS در شکل (2) نشان داده شده است و توضیحات جامع‌تری را می‌توان در [20] یافت. این سیستم شامل پنج لایه اصلی است و به طور پیش‌فرض از یک رویکرد یادگیری هیبریدی استفاده می‌کند که ترکیبی از روش تخمین حداقل مربعات و پس‌انتشار خطا برای آموزش و تنظیم پارامترها می‌باشد. با بهینه‌سازی پارامترهای اولیه و هم پارامترهای خروجی، ANFIS قادر است یک نگاهت منطقی و غیرخطی بین ورودی‌ها و خروجی‌های سیستم ایجاد کند.



شکل 2- ساختار ANFIS [20]

⁸ Partial Least Squares Regression

2-2- الگوریتم بهینه‌سازی Solifugae (SIOA)


الگوریتم‌های بهینه‌سازی الهام‌گرفته از طبیعت اغلب قدرت خود را از تقلید رفتارهای سازگار و غریزی موجودات در دنیای حیوانات می‌گیرند. رفتار شکارگری Solifugae یک عنکبوت‌سان معروف به سرعت، دقت و استراتژی‌های بقای خود در محیط‌های سخت پایه‌ای جذاب برای طراحی یک الگوریتم فراابتکاری قدرتمند ارائه می‌دهد. اصول اصلی بسیاری از رفتارهای آن می‌تواند انتزاع شده و به استراتژی‌های محاسباتی مؤثری برای حل مشکلات پیچیده بهینه‌سازی ترجمه شود.

اولین اصل سرعت و چابکی است که مستقیماً با فاز کاوش یک الگوریتم بهینه‌سازی ارتباط دارد. Solifugae به دلیل حرکت سریع و پیش‌دستانه خود هنگام شکار شناخته شده‌اند، نه با استفاده از روش‌های تله‌گذاری منفعلانه. این ویژگی می‌تواند الهام‌بخش عنصری در الگوریتم باشد که کاوش سریع و گسترده‌ای از فضای راه‌حل را در مراحل اولیه بهینه‌سازی انجام می‌دهد. با اسکن سریع یک دامنه وسیع از پاسخ‌های کاندیدا، الگوریتم می‌تواند از همگرایی زودهنگام جلوگیری کرده و به طور مؤثرتری از بهینه‌های محلی فرار کند. دومین اصل، شناسایی لرزش است که می‌توان آن را با فاز بهره‌برداری بهینه‌سازی معادل‌سازی کرد. Solifugae لرزش‌های جزئی زمین را برای شناسایی طعمه تشخیص می‌دهند، رفتاری که می‌تواند به طور استعاری نمایانگر توانایی الگوریتم در شناسایی و واکنش به مناطق امیدوارکننده در فضای جستجو باشد. در عمل، این می‌تواند به عنوان یک مکانیزم بازخورد پیاده‌سازی شود که به الگوریتم این امکان را می‌دهد تا به طور تطبیقی تمرکز خود را محدود کرده و جستجو را در نواحی با عملکرد بالا بر اساس تناسب پاسخ‌های ارزیابی شده دقیق‌تر کند.

رفتار کمین و تعقیب که در Solifugae مشاهده می‌شود نمایانگر یک استراتژی جستجوی تشدید شده است. هنگامی که یک طعمه بالقوه شناسایی می‌شود، Solifugae به سرعت نزدیک شده و تمام تلاش خود را برای شکار آن اختصاص می‌دهند. به طور مشابه، الگوریتم پیشنهادی می‌تواند از مکانیزم جستجوی محلی تطبیقی استفاده کند که جستجو را در اطراف نواحی با پتانسیل بالا تشدید کند. این تغییر پویا از جستجوی سرتاسری به جستجوی محلی امکان بهره‌برداری عمیق‌تر از نواحی امیدوارکننده را فراهم می‌آورد، تخصیص منابع را بهینه کرده و سرعت همگرایی به سوی پاسخ بهینه را تسریع می‌کند.

ویژگی کلیدی دیگر گاز گرفتن خردکننده Solifugae است که می‌توان آن را به فاز تصفیه در فرآیند بهینه‌سازی تشبیه کرد. پس از شکار طعمه، Solifugae آن را به دقت تجزیه می‌کند. مشابه این، پس از شناسایی یک پاسخ نزدیک به بهینه، الگوریتم می‌تواند به تنظیم دقیق مشغول شود پاسخ را برای حذف نادرستی‌های جزئی و افزایش دقت و مقاومت کلی آن بهبود بخشد. در نهایت، رفتار شبانه Solifugae الهام‌بخش مدیریت منابع تطبیقی و واکنش استراتژیک به شرایط محیطی است. فعال بودن در دوره‌های خنک‌تر و مطلوب‌تر نشان می‌دهد که مدلی باید به‌طور تطبیقی بر اساس عوامل موقعیتی تنظیم شود. در زمینه بهینه‌سازی، این ممکن است به معنای تنظیم استراتژی‌های الگوریتمی یا تخصیص منابع محاسباتی به صورت پویا در پاسخ به پیچیدگی مسئله، عملکرد سیستم یا نیازهای در حال تکامل جستجو باشد.

مجموعاً، این اصول زیستی الهام‌بخش به عنوان پایه‌ای برای توسعه یک چارچوب بهینه‌سازی جدید، کارآمد و تطبیقی، تحت عنوان الگوریتم بهینه‌سازی Solifugae عمل می‌کند که برای مقابله با چالش‌های مرتبط با مسائل بهینه‌سازی با ابعاد بالا و پویا طراحی شده است. ویژگی‌های رفتاری Solifugae که به عنوان الهام‌بخش الگوریتم SIOA پیشنهادی مورد استفاده قرار گرفته‌اند، در شکل (3) نشان داده شده است.



شکل 3- مشخصه‌های رفتاری Solifugae

3-2- آموزش ANFIS

در این مقاله، الگوریتم بهینه‌سازی Solifugae برای آموزش ANFIS از طریق تعیین پارامترهای بهینه آن استفاده می‌شود. تعداد پارامترهای اولیه در ANFIS با استفاده از معادله (1) محاسبه می‌شود.

$$IniPar_{No.} = \sum_{k=1}^K a_k \quad (1)$$

که K نمایانگر تعداد توابع عضویت است، و a_k پارامتری است که با نوع تابع عضویت استفاده شده مرتبط است. به عنوان مثال، اگر تابع عضویت گاوسی باشد، مقدار K برابر با 2 است، زیرا تابع عضویت گاوسی دارای دو پارامتر است: مرکز (C) و عرض (σ). تعداد پارامترهای به دست آمده به طور مستقیم با تعداد متغیرهای ورودی و تعداد قواعد فازی مرتبط است. این رابطه را می‌توان با استفاده از معادله (2) بیان و محاسبه کرد.

$$Par_{No.} = Rule_{No.} \times (T + 1) \quad (2)$$

که در آن $Rule_{No.} = \prod_{i=1}^T A_i$ است و A_i نمایانگر تعداد توابع عضویت استفاده شده برای متغیر i -ام است، و T تعداد متغیرهای ورودی را نشان می‌دهد. جذر میانگین مربعات خطا (RMSE) یک معیار آماری رایج برای مسائل برآورد پارامترها است. معادله (3) این کمیت را تعریف می‌کند که به عنوان تابع هدف در فرآیند آموزش ANFIS در این مقاله استفاده می‌شود.

$$RMSE = \sqrt{\frac{\sum_{s=1}^{NS} (VSM_{act}(s) - VSM_{est}(s))^2}{NS}} \quad (3)$$

در این معادله، VSM_{act} و VSM_{est} به ترتیب نمایانگر حد پایداری واقعی و تخمینی هستند. NS نمایانگر تعداد کل نمونه‌ها است، و s شماره نمونه را نشان می‌دهد. پارامترهای بهینه ANFIS با استفاده از الگوریتم SIOA تعیین می‌شوند تا تابع هدف (3) به حداقل برسد.

4-2- روش کاهش ویژگی مبتنی بر PLSR

رگرسیون حداقل مربعات جزئی (PLSR) یک روش آماری است که برای مدل‌سازی روابط بین مجموعه‌ای از متغیرهای پیش‌بین (متغیرهای مستقل) و متغیرهای پاسخ (متغیرهای وابسته) استفاده می‌شود. این روش به ویژه زمانی مفید است که پیش‌بین‌ها هم‌بسته بسیار بالا باشند یا زمانی که تعداد پیش‌بین‌ها بیشتر از مشاهدات باشد، که در زمینه‌هایی مانند شیمی‌سنجی، علوم اجتماعی و بیوانفورماتیک یک پدیده رایج است [21].

PLSR به چالش‌های مهم در تحلیل رگرسیون پاسخ می‌دهد، به ویژه زمانی که با داده‌های با ابعاد بالا و چندهمبستگی مواجه هستیم. این روش با ایجاد متغیرهای پنهانی جدید (مؤلفه‌ها) که ترکیب‌های خطی از پیش‌بین‌های اصلی هستند، فضای پیش‌بین را با کاهش ابعاد کاهش می‌دهد. این مؤلفه‌ها به گونه‌ای انتخاب می‌شوند که کوواریانس بین پیش‌بین‌ها و پاسخ‌ها را به حداکثر برسانند.

در پیاده‌سازی دو بعدی PLSR، هدف اصلی پیش‌بینی ماتریس پاسخ Y از ماتریس پیش‌بین X با شناسایی مجموعه‌ای از متغیرهای پنهان یا مؤلفه‌ها است. گام اولیه شامل مرکز کردن داده‌ها است، که با کم کردن میانگین هر متغیر—هم پیش‌بین‌ها و هم پاسخ‌ها از مقادیر مربوطه انجام می‌شود، به صورت زیر:

$$\begin{aligned} \bar{X} &= X - \bar{X} \\ \bar{Y} &= Y - \bar{Y} \end{aligned} \quad (4)$$

که در آن \bar{X} و \bar{Y} به ترتیب میانگین هر ستون از X و Y هستند. سپس، متغیرهای پنهان محاسبه می‌شوند. این متغیرهای پنهان (مؤلفه‌ها) از هر دو ماتریس پیش‌بین X و ماتریس پاسخ Y روابط زیربنایی بین X و Y را به تصویر می‌کشند. امتیازهای پیش‌بین T و امتیازهای پاسخ U با ترکیب‌های خطی از متغیرهای اصلی محاسبه می‌شوند، به صورت زیر:

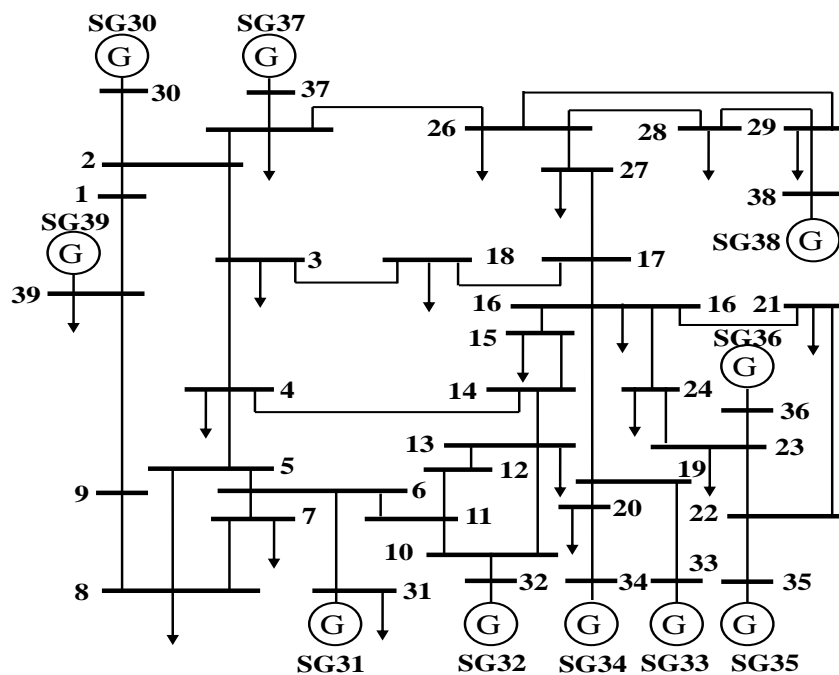
$$\begin{aligned} X &= TP^T + E \\ Y &= UQ^T + F \end{aligned} \quad (5)$$

که در آن T نمایانگر امتیازهای پیش‌بین است که ماتریس متغیرهای پنهانی استخراج شده از X را تشکیل می‌دهد. ماتریس P شامل بارگذاری‌ها یا بردارهای وزن مربوط به پیش‌بین‌ها است. ماتریس E نشان‌دهنده باقی‌مانده‌های ماتریس پیش‌بین است که بخش از X را که توسط مدل توضیح داده نمی‌شود، ضبط می‌کند. به‌طور مشابه، U نمایانگر امتیازهای پاسخ است که معادل با متغیرهای پنهانی استخراج شده از Y هستند، در حالی که Q شامل بارگذاری‌ها برای متغیرهای پاسخ است. در نهایت، ماتریس F باقی‌مانده‌ها برای پاسخ‌ها است که تغییرات غیرقابل توضیح در Y پس از مدل‌سازی را نشان می‌دهد. هدف اصلی PLSR استخراج مؤلفه‌های پنهانی است که ویژگی‌های غالب را نمایان می‌سازند و کوواریانس بین امتیازهای پیش‌بین (T) و امتیازهای پاسخ (U) را به حداکثر می‌رسانند. این کار از طریق یک فرآیند تکراری برای به حداکثر رساندن تابع هدف زیر انجام می‌شود:

$$\max \text{Cov}(T, U) = \frac{\text{cov}(T, U)^2}{\text{var}(T) \cdot \text{var}(U)} \quad (6)$$

3. نتایج و تحلیل آن‌ها

مدل تخمین‌گر پیشنهادی که در شکل (1) نشان داده شده است، بر روی سیستم قدرت 39 باس که در شکل (4) به تصویر کشیده شده است، پیاده‌سازی شده است. این سیستم آزمایشی شامل 10 ژنراتور، 29 باس P-Q، 9 باس P-V، 46 خط انتقال و یک باس اسلک (که باس شماره 39 شناخته می‌شود) با ولتاژ معین $|V_{bus-39}| = 1$ و زاویه ولتاژ $\delta_{bus-39} = 0^\circ$ است. اطلاعات دقیق‌تری در مورد پیکربندی سیستم در [22] موجود است. تمام شبیه‌سازی‌ها با استفاده از MATLAB R2021b بر روی کامپیوتری مجهز به پردازنده Intel Core i7 و 64 گیگابایت رم انجام شد.



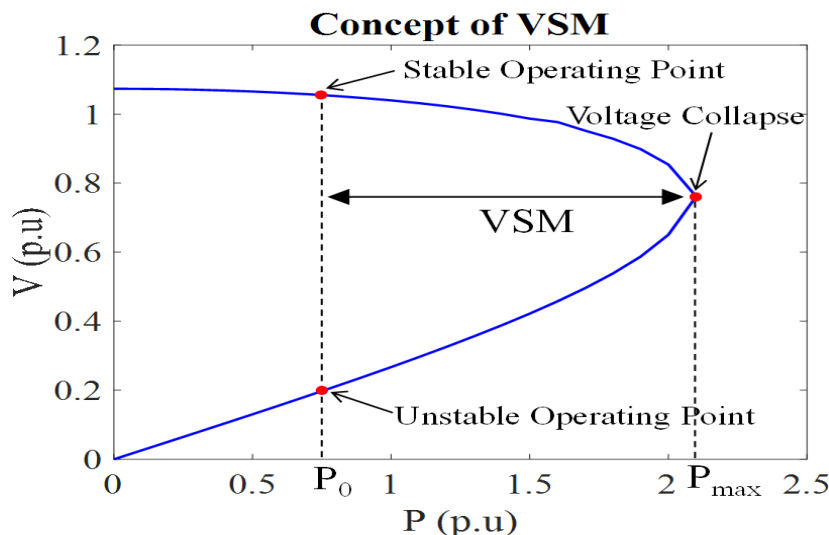
شکل 4- سیستم استاندارد 39 باس IEEE [22]

در این مطالعه فرض بر این است که تمام داده‌های اندازه‌گیری مربوط به باس‌های سیستم آزمایشی از طریق PMU‌ها در دسترس است. ویژگی‌های بارگذاری سیستم به‌عنوان ویژگی‌های اصلی انتخاب شده‌اند، که از آن‌ها ویژگی‌های غالب با استفاده از مدل استخراج ویژگی مبتنی بر PLSR استخراج می‌شوند. دلیل انتخاب ویژگی‌های بارگذاری به‌عنوان ویژگی‌های اصلی

عبارت است از: اولاً، رویدادهای فروپاشی ولتاژ عمدتاً تحت شرایط بار بالا رخ می‌دهند؛ و ژنراتورهای سنکرون که منابع اصلی توان راکتیو هستند نقش حیاتی در حفظ پایداری ولتاژ در داخل شبکه قدرت ایفا می‌کنند. ویژگی‌های اصلی برای سیستم 39 باس IEEE شامل متغیرهای زیر است:

- اندازه ولتاژ 9 باس P-V (9 متغیر)
- اندازه ولتاژ باس اسلک (1 متغیر)
- توان اکتیو در باس اسلک (1 متغیر)
- توان راکتیو در باس اسلک (1 متغیر)
- توان اکتیو تولید شده توسط 9 باس P-V (9 متغیر)
- توان اکتیو مصرف شده در 29 باس P-Q (29 متغیر)
- توان راکتیو مصرفی در 29 باس P-Q (29 متغیر)

در مجموع، 79 متغیر در نظر گرفته شده است که هر یک از آن‌ها پتانسیل تأثیرگذاری بر حد پایداری ولتاژ شبکه را دارند. به‌طور متعاقب، مجموعه داده اولیه که برای آموزش و آزمایش ANFIS بهینه استفاده می‌شود، بر اساس این 79 متغیر اصلی ساخته شده است. هر نمونه آموزشی معادل یک مقدار عددی از VSM است. به‌طور رسمی، حد پایداری ولتاژ نمایانگر فاصله بین نقطه عملیاتی فعلی سیستم P_0 و نقطه فروپاشی ولتاژ P_{max} است. این مفهوم برای یک سیستم قدرت فرضی در شکل (5) نشان داده شده است.

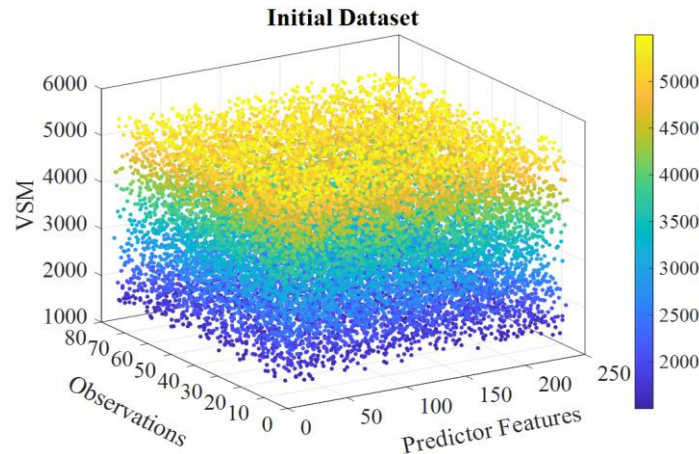


شکل 5- مفهوم حد پایداری ولتاژ

مجموعه اولیه متغیرهای شبکه تحت سه سناریو متفاوت ساخته می‌شود: (i) سناریو پیش فرض، (ii) سناریو افزایش که نمایانگر افزایش 20٪ از مقادیر نامی برای متغیرهای توان اکتیو و راکتیو و افزایش 5٪ برای مقادیر ولتاژ باس‌ها است، و (iii) سناریو کاهش که معادل کاهش 20٪ در متغیرهای توان اکتیو و راکتیو و کاهش 5٪ در مقادیر ولتاژ باس‌ها می‌باشد. در نتیجه، مجموعه کامل متغیرهای اولیه شامل $237 = 3 \times 79$ متغیر می‌باشد.

بر اساس روش موجود در [19]، از یک الگوی تغییر بار برای تولید مجموعه داده اولیه جهت آموزش و آزمایش ANFIS استفاده می‌شود. با این حال، برخلاف آثار مرجع، الگوهای بارگذاری در این مطالعه به‌طور تصادفی انتخاب شده‌اند. برای هر یک از 237 متغیر، مقادیر در شرایط بارگذاری تصادفی مختلف محاسبه می‌شوند، که از تکنیک جریان بار جداسازی سریع [23] استفاده می‌شود. این سناریوهای بارگذاری در بازه‌ای از 7000 مگاوات تا 12,800 مگاوات شبیه‌سازی می‌شوند. این فرآیند منجر به تولید یک ماتریس داده اولیه با ابعاد 237×75 می‌شود که در مجموع شامل 17,775 نقطه داده است، که هر ورودی داده معادل یک مقدار توان بیشینه (P_{max}) است و به این ترتیب یک مقدار عددی برای حد پایداری ولتاژ به‌دست می‌آید.

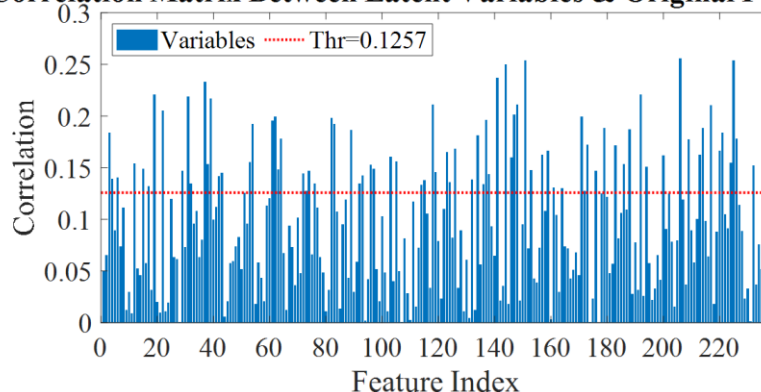
مجموعه داده اولیه برای آموزش و تست ANFIS بسیار بزرگ است و نیاز به کاهش ابعاد برای بهبود عملکرد و کارایی محاسباتی مدل تخمین‌گر دارد. برای این منظور، در این مطالعه از تکنیک رگرسیون 2D-PLSR استفاده شده است. ماتریس داده اولیه با ابعاد 237×75 در شکل (6) نشان داده شده است، که شامل $p=237$ ویژگی پیش‌بینی‌کننده و $n=75$ مشاهدات یا نمونه‌ها است که توسط ماتریس X نمایش داده می‌شود. ماتریس پاسخ Y یک بردار با 237 عنصر است که معادل مقادیر VSM تحت شرایط بارگذاری نامی شبکه است. این مقادیر VSM با اعمال تکنیک FDLF بر روی پیکربندی پیش‌فرض شبکه بدون تغییر در بارگذاری محاسبه می‌شوند.




شکل 6- مجموعه داده اولیه

گام بعدی تعیین متغیرهای پنهانی است که بیشترین همبستگی را بین X و Y به حداکثر می‌رسانند. این متغیرهای پنهان معادل مقادیر وزنی غالب در ماتریس همبستگی P هستند که در شکل (7) نشان داده شده است. استخراج متغیرهای نهفته از ماتریس P بر اساس یک مقدار آستانه تطبیقی انجام می‌شود. این آستانه می‌تواند به روش‌های مختلفی به دست آید، از جمله از طریق مقدار میانگین ماتریس همبستگی، صدک‌ها، توزیع داده‌ها در داخل ماتریس همبستگی، یا واریانس توضیح داده شده. در این مطالعه، به منظور کاهش بار محاسباتی، مقدار میانگین ماتریس همبستگی به عنوان آستانه انتخاب شده است. شکل (8) ماتریس ویژگی‌های استخراج شده با استفاده از رگرسیون PLSR را نشان می‌دهد. از این ماتریس که شامل 6075 نمونه است، 4535 نمونه ($\sim 75\%$) برای آموزش ANFIS اختصاص داده می‌شود، در حالی که 1540 نمونه ($\sim 25\%$) برای تست نگهداری می‌شوند.

Correlation Matrix Between Latent Variables & Original Features




شکل 7- متغیرهای پنهان متناظر با مقادیر وزنی غالب در ماتریس همبستگی



شکل ۸- ماتریس ویژگی‌های غالب استخراجی توسط PLSR

3-1- نتایج آموزش ANFIS

برای طراحی بهینه و آموزش ANFIS، در این مطالعه از SIOA پیشنهادی استفاده می‌شود. در ANFIS، توابع عضویت (MFs) نقش حیاتی در تعریف نحوه فازی کردن ورودی‌ها دارند. هدف اصلی استفاده از الگوریتم بهینه‌سازی، تعیین مجموعه بهینه‌ای از پارامترها برای این توابع عضویت است که خطا بین خروجی‌های پیش‌بینی شده و واقعی هدف را در طول مرحله آموزش به حداقل برساند. در این مقاله، از سه تابع عضویت گوسی برای مدل‌سازی 81 ویژگی انتخاب‌شده از طریق رگرسیون 2D-PLSR استفاده شده است. هر ویژگی با دو پارامتر مرکز و عرض که توسط سه تابع عضویت نمایش داده می‌شوند، شبیه‌سازی می‌شود. نتایج بهینه‌سازی پارامترهای مرکز و عرض برای این سه تابع عضویت در طول فرآیند طراحی ANFIS، با استفاده از روش SIOA، در شکل (9) ارائه شده است. بهترین پاسخ، مقدار میانگین و انحراف معیار تابع هدف در پنج اجرای الگوریتم پیشنهادی در جدول (1) ارائه شده است. مشخص است که الگوریتم SIOA پس از حدود 20 تکرار به مقدار نهایی RMSE برابر با $10.4281 \pm 5\%$ همگرا می‌شود.



شکل 9- مقدار تابع هدف (3) طی 500 تکرار برای 5 اجرای الگوریتم SIOA، مربوط به سیستم 39 باسه IEEE


جدول (1): بهترین پاسخ، مقدار میانگین و انحراف معیار تابع هدف طی پنج اجرای الگوریتم در فرآیند آموزش ANFIS.

الگوریتم بهینه‌سازی	RMSE		
	بهترین پاسخ	مقدار متوسط	انحراف استاندارد
SIOA	13.9806	14.0736	0.1593

3-2- مطالعه مقایسه‌ای


برای ارزیابی عملکرد مدل برآورد پیشنهادی مبتنی بر ANFIS-SIOA+PLSR، 10 شرایط بحرانی در سیستم آزمایشی 39 باس شبیه‌سازی شده‌اند، که بر اساس روش‌شناسی ارائه شده در [19] انجام شده است. این 10 شرایط بحرانی به شرح زیر است. علاوه بر این، شکل (10) مقادیر واقعی VSM را همراه با شرایط بحرانی شبیه‌سازی شده نشان می‌دهد.

- نقطه اولیه (شرایط عادی)
- افزایش بار (شرایط عادی)
- کاهش بار (شرایط عادی)
- تغییرات کوچک بار
- خروج خط 15-16
- افزایش کوچک بار
- اتصال خط 15-16
- تغییرات کوچک بار
- جبران توان راکتیو با تزریق 300 مگاوات به باس 4
- افزایش کوچک بار



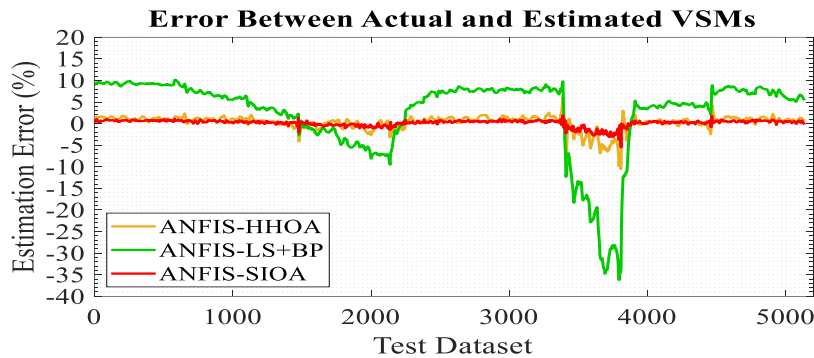
شکل 10- پروفایل واقعی حد پایداری ولتاژ تحت شرایط بحرانی مختلف در سیستم 39 باس IEEE.

علاوه بر این، مدل‌هایی مبتنی بر ANFIS-LS+BP و مدل ANFIS-HHOA، همان‌طور که در [19] پیشنهاد شده‌اند، برای برآورد VSM تحت این شرایط پیاده‌سازی شده‌اند. در ادامه، مدل پیشنهادی ANFIS-SIOA+PLSR پیاده‌سازی شده و نتایج آن با نتایج دیگر تخمین‌گرها مقایسه می‌شود، همان‌طور که در شکل (11) نشان داده شده است. درصد خطای برآورد نیز در شکل (12) نمایش داده شده است.



شکل 11- مقایسه مقادیر واقعی و تخمینی VSM با استفاده از ANFIS-SIOA و ANFIS-HHOA، ANFIS-LS+BP برای سیستم 39 باس IEEE

سیستم 39 باس IEEE



شکل 12- درصد خطای برآورد VSM با استفاده از ANFIS-LS+BP، ANFIS-HHOA و ANFIS-SIOA پیشنهادی برای سیستم 39 باسه IEEE

تحلیل مقایسه‌ای مقادیر نهایی RMSE و زمان‌های اجرا برای الگوریتم‌های مختلف در جدول (2) ارائه شده است که عملکرد الگوریتم پیشنهادی را در کنار الگوریتم‌های گزارش شده در [19]، [24]، [25] و [26] نشان می‌دهد. در [24]، از یک شبکه عصبی مصنوعی مبتنی بر تابع پایه شعاعی (RBF-NN) برای برآورد VSM استفاده شده است، و تکنیک MRWT-PCA برای استخراج ویژگی‌ها به کار رفته است. در [25]، از یک شبکه عصبی چندلایه پرسپترون (MLP-NN) به‌عنوان تخمین‌گر استفاده شده است، در حالی که فرآیند گرام-اشمیت اورتوگنالیزه‌سازی (GSO) برای استخراج ویژگی‌ها اعمال شده است. در [26]، پایداری ولتاژ با استفاده از ماشین بردار پشتیبان با حداقل مربعات وزنی (WLS-SVM) ارزیابی شده است. پایش زمان واقعی با استفاده از داده‌های PMU انجام می‌شود و دقت آن از طریق هماهنگی بهینه رله‌ها و کاهش ابعاد از طریق PCA بهبود می‌یابد. از آنجا که مطالعات مرجع، مشخصات محیط محاسباتی، از جمله مشخصات سخت‌افزاری یا نسخه MATLAB استفاده شده را ذکر نکرده‌اند، این مطالعه از نسخه استاندارد MATLAB و پیکربندی کامپیوتر معمولی استفاده کرده است تا ارزیابی منصفانه و یکسانی انجام دهد.

جدول (2): مقایسه زمان اجرای الگوریتم و مقدار نهایی RMSE برای سیستم 39 باس IEEE

مرجع	روش تخمین	روش استخراج ویژگی	RMSE	زمان اجرا (ثانیه)
[19]	ANFIS-HHOA	AR	23.91	1.52
[24]	RBF-NN	MRWT-PCA	27.85	6.95
[25]	MLP-NN	GSO	29.21	4.31
[26]	WLS-SVM	PCA	18.15	0.79
روش پیشنهادی	ANFIS-LS+BP	PLSR	30.0428	3.98
	ANFIS-HHOA	PLSR	21.6514	1.43
	ANFIS-SIOA	PLSR	13.9806	0.76

4. نتیجه‌گیری

این مقاله یک روش آنلاین برای تخمین حد پایداری ولتاژ در سیستم‌های قدرت با استفاده از یک سیستم استنتاج فازی عصبی تطبیقی بهینه‌شده (ANFIS) ارائه می‌دهد. آموزش مدل ANFIS با استفاده از یک الگوریتم بهینه‌سازی جدید الهام گرفته از طبیعت به نام الگوریتم بهینه‌سازی Solifugae (SIOA) انجام می‌شود، در حالی که استخراج ویژگی‌ها و انتخاب ویژگی‌های غالب از طریق تکنیک رگرسیون حداقل مربعات جزئی (PLSR) به‌دست می‌آید. نتایج شبیه‌سازی نشان می‌دهد که مدل پیشنهادی می‌تواند حد پایداری ولتاژ را تحت شرایط مختلف سیستم به‌طور دقیق برآورد کند و از سایر مطالعات مشابه پیشی گرفته و خطاهای برآورد را به‌طور قابل توجهی کاهش دهد. یکپارچه‌سازی روش رگرسیون PLSR به مدل این امکان را می‌دهد که هر سیستم قدرتی را بدون محدودیت در اندازه یا ابعاد تحلیل کند و انتخاب متغیر غالب برای تحلیل را تسهیل می‌کند. علاوه بر این، فرآیند آموزش ANFIS با استفاده از الگوریتم SIOA دقت بسیار بالاتر و همگرایی سریع‌تری به‌سمت پاسخ

نهایی نسبت به روش‌های سنتی نشان می‌دهد. مقایسه نتایج مدل پیشنهادی با سایر روش‌های برآورد اعمال شده بر روی سیستم 39 باسه، عملکرد برتر مدل برآورد ANFIS-SIOA+PLSR را از نظر دستیابی به مقادیر حداقل RMSE، کاهش خطاهای برآورد نرمال شده و بهبود کارایی محاسباتی نشان می‌دهد.

5. منابع و مراجع

1. J. Dong et al., "Key issues and technical applications in the study of power markets as the system adapts to the new power system in China," *Sustainability*, vol. 13, no. 23, p. 13409, Dec. 2021, (doi: 10.3390/su132313409).
2. S. K. Sahu, N. Sonal, D. Ghosh, D. K. Mohanta, and S. Dutta, "Operational Reliability and Non-Deterministic Resilience Estimation of active distribution network incorporating effect of Real-Time dynamic hosting capacity," *Sustainable Energy Grids and Networks*, vol. 40, p. 101541, Oct. 2024, (doi: 10.1016/j.segan.2024.101541).
3. H. Gao, G. Cai, D. Yang, and L. Wang, "Real-time long-term voltage stability assessment based on eGBDT for large-scale power system with high renewables penetration," *Electric Power Systems Research*, vol. 214, p. 108915, Nov. 2022, (doi: 10.1016/j.epsr.2022.108915).
4. H. Yang, R. C. Qiu, X. Shi, and X. He, "Unsupervised feature learning for online voltage stability evaluation and monitoring based on variational autoencoder," *Electric Power Systems Research*, vol. 182, p. 106253, Feb. 2020, (doi: 10.1016/j.epsr.2020.106253).
5. S. Liu et al., "A Data-Driven and Data-Based framework for online voltage stability assessment using partial mutual information and iterated random forest," *Energies*, vol. 14, no. 3, p. 715, Jan. 2021, (doi: 10.3390/en14030715).
6. K. Alzaareer, M. Saad, H. Mehrjerdi, C. Z. El-Bayeh, D. Asber, and S. Lefebvre, "A new sensitivity approach for preventive control selection in real-time voltage stability assessment," *International Journal of Electrical Power & Energy Systems*, vol. 122, p. 106212, May 2020, (doi: 10.1016/j.ijepes.2020.106212).
7. C. Lambrou, P. Mandoulidis, and C. Vournas, "Validation of voltage instability detection and control using a real power system incident," *Energies*, vol. 14, no. 21, p. 7165, Nov. 2021, (doi: 10.3390/en14217165).
8. A. Khurram, A. Gusnanto, and P. Aristidou, "A feature-subspace-based ensemble method for estimating long-term voltage stability margins," *Electric Power Systems Research*, vol. 212, p. 108481, Jul. 2022, (doi: 10.1016/j.epsr.2022.108481).
9. M. Ali, E. Gryazina, O. Khamisov, and T. Sayfutdinov, "Online assessment of voltage stability using Newton-Corrector algorithm," *IET Generation Transmission & Distribution*, vol. 14, no. 19, pp. 4207–4216, Jun. 2020, (doi: 10.1049/iet-gtd.2019.1200).
10. R. Pourbagher, S. Y. Derakhshandeh, and M. E. H. Golshan, "A novel method for online voltage stability assessment based on PMU measurements and Thevenin equivalent," *IET Generation Transmission & Distribution*, vol. 16, no. 9, pp. 1780–1794, Jan. 2022, (doi: 10.1049/gtd2.12400).
11. J. Pan, A. Dong, J. Fan, and Y. Li, "Online Static Voltage Stability Monitoring for power systems using PMU data," *Mathematical Problems in Engineering*, vol. 2020, pp. 1–8, Dec. 2020, (doi: 10.1155/2020/6667842).
12. P. Mandoulidis and C. Vournas, "A PMU-based real-time estimation of voltage stability and margin," *Electric Power Systems Research*, vol. 178, p. 106008, Oct. 2019, (doi: 10.1016/j.epsr.2019.106008).
13. L. M. Putranto and I. F. Azhar, "A proposed PMU-based voltage stability and critical bus detection method using artificial neural network," *Energy Informatics*, vol. 7, no. 1, Jan. 2024, (doi: 10.1186/s42162-024-00302-w).
14. A. Adhikari, S. Naetiladdanon, and A. Sangswang, "Real-Time Short-Term voltage stability assessment using combined temporal convolutional neural network and Long Short-Term Memory

- neural Network,” *Applied Sciences*, vol. 12, no. 13, p. 6333, Jun. 2022, (doi: 10.3390/app12136333).
15. A. Bressane, A. J. Da Silva Garcia, M. V. De Castro, S. D. Xerfan, G. Ruas, and R. G. Negri, “Fuzzy Machine Learning Applications in Environmental Engineering: Does the Ability to Deal with Uncertainty Really Matter?,” *Sustainability*, vol. 16, no. 11, p. 4525, May 2024, (doi: 10.3390/su16114525).
 16. N. Talpur, S. J. Abdulkadir, H. Alhussian, M. H. Hasan, N. Aziz, and A. Bamhdi, “Deep Neuro-Fuzzy System application trends, challenges, and future perspectives: a systematic survey,” *Artificial Intelligence Review*, vol. 56, no. 2, pp. 865–913, Apr. 2022, (doi: 10.1007/s10462-022-10188-3).
 17. X. Liu, S. H. Hussein, K. H. Ghazali, T. M. Tung, and Z. M. Yaseen, “Optimized Adaptive Neuro-Fuzzy inference System using metaheuristic algorithms: application of shield tunnelling ground surface settlement prediction,” *Complexity*, vol. 2021, no. 1, Jan. 2021, (doi: 10.1155/2021/6666699).
 18. S. Oladipo, Y. Sun, and O. Adeleke, “An improved particle swarm optimization and adaptive Neuro-Fuzzy inference system for predicting the energy consumption of university residence,” *International Transactions on Electrical Energy Systems*, vol. 2023, pp. 1–16, Mar. 2023, (doi: 10.1155/2023/8508800).
 19. A. Ghaghishpour and A. Koochaki, “An intelligent method for online voltage stability margin assessment using optimized ANFIS and associated rules technique,” *ISA Transactions*, vol. 102, pp. 91–104, Feb. 2020, (doi: 10.1016/j.isatra.2020.02.028).
 20. O. B. Adewuyi and S. Krishnamurthy, “Performance analysis for predictive voltage stability monitoring using enhanced Adaptive Neuro-Fuzzy Expert System,” *Mathematics*, vol. 12, no. 19, p. 3008, Sep. 2024, (doi: 10.3390/math12193008).
 21. T. Mehmood, S. Sæbø, and K. H. Liland, “Comparison of variable selection methods in partial least squares regression,” *Journal of Chemometrics*, vol. 34, no. 6, Feb. 2020, (doi: 10.1002/cem.3226).
 22. T. Athay, R. Podmore, and S. Virmani, “A practical method for the direct analysis of transient stability,” *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-98, no. 2, pp. 573–584, Mar. 1979, (doi: 10.1109/tpas.1979.319407).
 23. Y. Yao and M. Li, “Designs of fast decoupled load flow for study purpose,” *Energy Procedia*, vol. 17, pp. 127–133, Jan. 2012, (doi: 10.1016/j.egypro.2012.02.073).
 24. S. Hashemi and M. R. Aghamohammadi, “Wavelet based feature extraction of voltage profile for online voltage stability assessment using RBF neural network,” *International Journal of Electrical Power & Energy Systems*, vol. 49, pp. 86–94, Feb. 2013, (doi: 10.1016/j.ijepes.2012.12.019).
 25. A. R. Bahmanyar and A. Karami, “Power system voltage stability monitoring using artificial neural networks with a reduced set of inputs,” *International Journal of Electrical Power & Energy Systems*, vol. 58, pp. 246–256, Feb. 2014, doi: 10.1016/j.ijepes.2014.01.019.
 26. A. H. Poursaeed and F. Namdari, “Real-time voltage stability monitoring using weighted least square support vector machine considering overcurrent protection,” *International Journal of Electrical Power & Energy Systems*, vol. 136, p. 107690, Oct. 2021, (doi: 10.1016/j.ijepes.2021.107690).

An ANFIS-based optimized model for online estimation of voltage stability margin in power networks using a novel SIOA algorithm and partial least squares-based dimensionality reduction technique

Ehsan Akbari

Department of Electrical Engineering, Mazandaran University of Science and Technology,
Babol, Iran
e.akbari@ustmb.ac.ir

Abstract—This paper addresses the challenge of online estimation of voltage stability margin (VSM) in power networks. Due to rapid fluctuations in load and variable operating conditions, fast and accurate estimation of VSM is essential to prevent instability events. With the expansion of power systems, the dimensionality of input data increases significantly, which necessitates the need for efficient feature selection and dimensionality reduction techniques. To address this challenge, an innovative hybrid intelligent approach is proposed that combines the adaptive neuro-fuzzy inference system (ANFIS) trained by the Solifugae-inspired optimization algorithm (SIOA) with partial least squares (PLS) regression for dimensionality reduction and dominant feature selection. The initial feature set consists of system loading features obtained from phasor measurement units (PMUs) and includes essential information about the network topology, load levels, generation patterns, and control system behavior. The effectiveness of the proposed ANFIS–SIOA+PLS framework is validated using IEEE 39 test system. Comparative analysis with existing models in the literature demonstrates the superior performance of the proposed method, especially in terms of feature reduction and convergence speed. It is noteworthy that the proposed approach achieves a 41.53% reduction in root mean square error (RMSE) for the 39 bus test system compared to the best results reported in the literature. This improvement confirms the efficiency and stability of the proposed method.

Keywords: Online estimation of voltage stability margin, Adaptive Neuro-Fuzzy Inference System (ANFIS), Solifugae-Inspired Optimization Algorithm (SIOA), Partial Least Squares (PLS) regression.