



Computational Intelligence in Electrical Engineering
Vol. 14, No. 2, 2023
Research Paper

Bad Data Detection in Electrical Grid's State Estimation due to Cyber Attack on Measurements Using DRGP and GSR algorithms

Samira Amini¹, Rahmat-Allah Hooshmand², Mohammad Ataei³

¹ Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran

² Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran

³ Dept. of Electrical Engineering, University of Isfahan, Isfahan, Iran

Abstract:

Nowadays, using telecommunication systems and advanced measuring devices underlies cyberattacks on electrical grids. Bad data injection and failure to detect it on time, cause drastic damage to the network. This paper presents a new method for bad data detection (BDD) in state estimating when a cyber attacker manipulates the important measurements. Therefore, the new attack index is defined by simultaneously manipulating the network parameters and injecting incorrect data into the measured values. For this purpose, considering the masking and swamping effect, the diagnostic robust generalized potential (DRGP) algorithm detected and isolated high-leverage measurements installed in important locations from low-leverage measurements. Then, the state estimation process performs using low-leverage measurements. The Generalized Studentized Residual (GSR) algorithm detects bad data. With simultaneous manipulation of network parameters and measurement values, conventional BDD methods are unable to detect an attack. To evaluate the performance of the proposed method, they were implemented on the IEEE standard 14-bus network using MATLAB and Rstudio software. The simulation results show the ability of the proposed algorithm to detect a bad data attack.

Keywords: State Estimation, Bad Data Detection, Cyberattack, Bad Data Injection Attack, Smart Grid.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/ISEE.2022.132857.1548>

تشخیص داده بد در تخمین حالت شبکه‌های قدرت در اثر حمله سایبری به

اندازه‌گیری‌ها با استفاده از الگوریتم‌های پتانسیل و باقیمانده تعمیم‌یافته

سمیرا امینی^۱، رحمت الله هوشمند^{۲*}، محمد عطایی^۳

۱- کارشناسی ارشد، گروه برق، دانشکده فنی و مهندسی - دانشگاه اصفهان - اصفهان - ایران

samira.amini@eng.ui.ac.ir

۲- استاد گروه برق، دانشکده فنی و مهندسی - دانشگاه اصفهان - اصفهان - ایران

hooshmand_r@eng.ui.ac.ir

۳- استاد گروه برق، دانشکده فنی و مهندسی - دانشگاه اصفهان - اصفهان - ایران

ataei@eng.ui.ac.ir

چکیده: گسترش استفاده از سیستم‌های مخابراتی و دستگاه‌های اندازه‌گیری پیشرفته در شبکه‌های قدرت، زمینه‌ساز برقراری حملات سایبری در این شبکه‌ها است. وقوع حمله تزریق داده بد و تشخیص‌ندادن به موقع آن، آسیب‌های جبران‌ناپذیری را به شبکه تحمیل می‌کند. در این مقاله، روش جدیدی به منظور تشخیص داده بد (BDD) در تخمین حالت، هنگامی که مهاجم سایبری اندازه‌گیری‌های حساس و مهم را اندازه‌گیری می‌کند، ارائه می‌شود. بدین منظور، شاخص جدید حمله با دستکاری کردن هم‌زمان پارامترهای شبکه و تزریق داده‌های اشتباه به مقادیر اندازه‌گیری شده تعریف می‌شود. در این صورت، ابتدا دستگاه‌های اندازه‌گیری با اهمیت و نفوذ بالا که در مکان‌های حساس نصب شده‌اند، از دستگاه‌های اندازه‌گیری با اهمیت و نفوذ پایین با وجود اثر *masking* و *swaming* با استفاده از الگوریتم پتانسیل تعمیم‌یافته و مطمئن (DRGP) تشخیص و جداسازی می‌شوند. بعد از این دسته‌بندی، مجدد^۱ فرآیند تخمین حالت با استفاده از اندازه‌گیری‌های با نفوذ پایین انجام می‌شود. اندازه‌گیری‌های حاوی داده بد با استفاده از الگوریتم باقیمانده تعمیم‌یافته (GSR) تشخیص داده می‌شوند. با دستکاری کردن هم‌زمان پارامترهای شبکه و مقادیر اندازه‌گیری‌ها، روش‌های معمول BDD قادر به تشخیص حمله نیستند. به منظور بررسی کارایی الگوریتم‌های تشخیص داده بد بیان‌شده، پیاده‌سازی آنها روی شبکه استاندارد ۱۴ و ۱۲۳ باسه IEEE با استفاده از نرم‌افزارهای MATLAB و Rstudio انجام شده است. نتایج، شبیه‌سازی توانایی الگوریتم پیشنهادی را در تشخیص حمله داده بد به خوبی نشان می‌دهند.

واژه‌های کلیدی: تخمین حالت، تشخیص داده بد، حمله سایبری، حمله تزریق داده بد، شبکه هوشمند.

۱- مقدمه

شبکه‌های برق، به بحث امنیتی و سایبری شبکه‌های هوشمند بسیار توجه شده است. شبکه‌های قدرت هوشمند با سیستم‌های سایبری پشتیبانی می‌شوند. در این راستا، استفاده از تکنولوژی ارتباطات و اطلاعات که به منظور افزایش کارایی، کیفیت و قابلیت اطمینان در پروسه‌های صنعتی، شبکه‌های قدرت و شبکه‌های واحد اندازه‌گیری فازور^۱ (PMU) به کار می‌رود، تهدیدات ناخواسته‌ای را متوجه این شبکه‌ها کرده است. این خطرات شامل حملات سایبری به منظور ایجاد وقفه در تولید، انتقال و توزیع برق یا

با گسترش و توسعه فناوری اطلاعات و ارتباطات در

^۱ تاریخ ارسال مقاله: ۱۴۰۰/۱۲/۰۵

تاریخ پذیرش مقاله: ۱۴۰۱/۰۴/۱۲

نام نویسنده مسئول: رحمت الله هوشمند

نشانی نویسنده مسئول: ایران، اصفهان - دانشگاه اصفهان -

دانشکده فنی و مهندسی - گروه برق

دینامیک تغییرات اندازه‌گیری با تحت تأثیر قرار گرفتن یک متغیر حالت، پرداخته شده است. در مرجع [۵] از آشکارساز متوالی براساس نسبت احتمال کلی به منظور تشخیص سریع BDD استفاده شده است. در مرجع [۶] به بیان استراتژی‌های حمله BDI در ناحیه‌های محلی با فرض دسترسی مهاجم سایبری به اطلاعات و توپولوژی بخش‌های محلی شبکه پرداخته شده است. از میان روش‌های BDD که بر مبنای مقایسه مقدار باقیمانده اندازه‌گیری (تفاضل بین اندازه‌گیری مشاهده‌شده و تخمین زده شده) با مقدار آستانه از پیش تعریف شده است، می‌توان به آزمون کای - مربع [۷]، آزمون باقیمانده نرمالیزه‌شده [۸، ۹]، شاخص فاصله مطلق (AD^0) [۱۰] و شاخص KLD^1 [۴] اشاره کرد.

ضعف عمده روش‌های سنتی تشخیص مبتنی بر تحلیل باقیمانده این است که براساس اندازه‌گیری‌های وابسته به هم است. در صورتی که چندین اندازه‌گیری با مهاجم دستکاری شوند، ممکن است به تولید مقدار باقیمانده نسبتاً بزرگ برای اندازه‌گیری‌هایی منجر شود که حتی آلوده به خطا نیستند [۱۱]. در مرجع [۱۲]، برای رفع این مشکل از تخمین مستقیم خطای اندازه‌گیری‌ها با بهره‌گیری از آزمون فرضیه استفاده شده است. عملکرد درست این روش در گروی محاسبات آماری پیچیده است [۷]. در مرجع [۱۱] از مدل پخش توان AC در روش تشخیص BDI با بهره‌گیری از ساختار گراف شبکه استفاده شده است. روش بیان‌شده در این مرجع قادر به تشخیص حملات BDI است که با استفاده از مدل‌های خطی‌سازی شده DC قابل تشخیص نبوده‌اند. در مرجع [۱۳] به بیان حملات سایبری به یکپارچگی و دسترس‌پذیری داده‌ها در تخمین حالت شبکه پرداخته شده است. همچنین، حملات یکپارچگی با حملات BDI مقایسه شده‌اند. در مرجع [۱۴] به بیان نحوه بهینه‌سازی تعداد اندازه‌گیری‌هایی پرداخته‌اند که باید برای تأثیر بر تعداد متغیرهای حالت داده شده دستکاری شوند.

در این مقاله، به منظور بررسی صحت و درستی داده‌های دریافتی در مرکز کنترل و تشخیص نفوذ داده بد به کمیت‌های اندازه‌گیری‌شده، از روش $DRGP^V$ -GSR استفاده شده است. به این منظور، استراتژی‌های جدید حمله، تعریف و از راه‌های متنوعی داده‌های جعلی به

همچنین، دستکاری داده‌های ارسالی در شبکه است. در بدترین حالت، وقوع این حملات به فروپاشی و خاموشی سراسری منجر خواهد شد [۱].

یکی از انواع حملات سایبری، حمله تزریق داده بد (BDD^1) است. در این نوع حمله با دستکاری کردن اندازه‌گیری‌ها و تزریق داده‌های غلط به پارامترهای شبکه در حین ارسال به مرکز کنترل، مسائل تخمین حالت^۲ و بهره‌برداری ایمن از شبکه با مشکل مواجه می‌شود. در جریان حمله، تلاش مهاجم مبنی بر حداکثرسازی خسارت با کمترین هزینه است. بنابراین، لایه‌های مختلف امنیت سایبری باید به نحوی طراحی شود که تهدیدهای این حملات را به حداقل برساند. همچنین لازم است از رویکردهای مبتنی بر تشخیص حمله، به منظور تشخیص داده بد (BDD^2) در اندازه‌گیری‌ها استفاده شود.

گام نخست در راستای تحلیل امنیت، مشاهده و نظارت بر حالت فعلی شبکه است که شامل دستیابی به اندازه‌گیری‌ها از تمامی قسمت‌ها و تحلیل آنها به منظور تخمین حالت‌های شبکه است [۲]. به منظور اطلاع از وضعیت شبکه، لازم است کمیت‌های اندازه‌گیری‌شده با سنسورها یا واحد اندازه‌گیری فازور از طریق بسترهای مخابراتی و اینترنتی به مرکز کنترل ارسال شود. سپس با استفاده از اندازه‌گیری‌های دریافت‌شده و بررسی رؤیت‌پذیری شبکه، حالت‌های شبکه تخمین زده می‌شود. داده‌ها و اندازه‌گیری‌ها ممکن است با مهاجم دستکاری شوند و اطلاعات جعلی به دست بهره‌بردار شبکه برسد. در صورت عدم تشخیص داده‌های اشتباه، برنامه‌های تخمین حالت، پخش بار، برنامه‌ریزی تولید، پیش‌بینی بار و اقدامات کنترلی شبکه به شدت تحت تأثیر قرار خواهند گرفت [۳]. در مقالات مختلف، برای حفاظت شبکه در مقابل حملات سایبری به دو اقدام عملیاتی مختلف اشاره شده است. نخستین روش بر مبنای اقدامات حفاظتی است که تمامی ادوات اندازه‌گیری موجود هر کدام به صورت مجزا حفاظت شوند. دومین روش بر مبنای تشخیص حملات با استفاده از الگوریتم‌های مختلف است. در این اقدام با تجزیه و تحلیل اندازه‌گیری‌های، موارد غیر معمول شناسایی می‌شوند. در مرجع [۴] به بیان BDD به صورت بلادرنگ براساس

در مجموعه نفوذ متعلق باشد، به مدیریت دقیق نیاز خواهد داشت.

اطلاعات ورودی به تخمین گر حالت شامل سه دسته است [۳]:

۱- اطلاعات دستگاههای اندازه گیری که شامل توان های تزریقی به باس ها و توان انتقالی در خطوط است؛ این اطلاعات با z نمایش داده می شوند.

۲- اطلاعات مربوط به توپولوژی شبکه که شامل وضعیت سوئیچ ها و بریکرها است و با t نمایش داده می شود.

۳- اطلاعات مربوط به پارامترها که شامل امپدانس خطوط و واریانس خطا مربوط به اندازه گیری ها است و با p نشان داده می شود.

به منظور مدل سازی جامع و بررسی دقیق شبکه با هدف دستکاری کردن مقادیر اندازه گیری های توسط مهاجم، از مدل تخمین حالت AC استفاده می شود [۱۰]. ارتباط غیرخطی بین بردار اندازه گیری و بردار حالت به صورت رابطه زیر بیان می شود [۱۵]:

$$z = h(x) + e \quad (1)$$

که h یک تابع غیر خطی بین بردار اندازه گیری z و بردار حالت x است و e بردار نویز اندازه گیری ها با توزیع نرمال و میانگین صفر است. بردار حالت x شامل اندازه و فاز ولتاژ باس ها است. ماتریس ژاکوبین با a ابعاد نشان داده می شود (m و n به ترتیب بیان کننده تعداد اندازه گیری ها و تعداد متغیرهای حالت است). برای تخمین حالت های شبکه، باید تعداد اندازه گیری ها از تعداد متغیرهای حالت بیشتر باشد. مهاجم با تزریق بردار حمله a به بردار اندازه گیری های z ، باعث تغییر در مقادیر اندازه گیری شده می شود.

$$z_{bad} = z + a \quad (2)$$

که بردار اندازه گیری دستکاری شده است. مقدار خطای c به بردار متغیرهای حالت بر اثر دستکاری کردن کمیت های اندازه گیری شده اضافه می شود. در صورت عدم تشخیص داده غلط تزریق شده به اندازه گیری ها، اقدامات اپراتور

کمیت های اندازه گیری تزریق شده اند. همچنین، به سبب حفظ امنیت کامل شبکه و تأثیر حمله در متغیرهای اندازه ولتاژ و زاویه باس، در روش ارائه شده از تخمین حالت AC با دقت بالا استفاده شده است. با توجه به اینکه اساس روش های تشخیص بر مبنای مقایسه مقدار باقیمانده با مقدار آستانه از پیش تعریف شده است، تلاش مهاجم بر دستکاری کردن اندازه گیری های متناظر با نقاط با نفوذ بالا (HLP) است؛ زیرا مقدار باقیمانده متناظر با این اندازه گیری ها کوچک است؛ بنابراین، با استفاده هم زمان از دو الگوریتم DRGP-GSR، همه انواع اندازه گیری های آلوده به خطا شناسایی می شوند. نتایج شبیه سازی، کارایی و توانایی الگوریتم های ارائه شده در مقابله سایر روش های تشخیص و انواع شاخص های حمله را نشان می دهند.

بخش های دیگر مقاله به شرح زیر سازماندهی شده اند. در بخش دوم، به بیان مدل سازی حمله و تأثیر آن در تخمین حالت شبکه پرداخته می شود. در بخش سوم، نقاط آسیب پذیر شبکه و مهم از دید مهاجم بیان می شود. در بخش چهارم، روش پیشنهادی برای تشخیص داده بد توضیح داده می شود. در بخش پنجم، نتایج شبیه سازی الگوریتم های ارائه شده روی شبکه نمونه بررسی می شوند.

۲- مدل سازی حمله BDI در تخمین حالت

برای بررسی شرایط بهره برداری سیستم، برآورد حالت های شبکه با استفاده از فرآیند تخمین حالت در مرکز کنترل انجام می شود. در حملات سایبری، مهاجم سعی دارد به نقاطی حمله کند که بیشترین آسیب را به شبکه وارد کند؛ به گونه ای که از سیستم های تشخیص داده بد عبور کند؛ بنابراین، مهاجم با دستکاری کردن پارامترهای متناظر با اندازه گیری ها سعی در ایجاد نقاطی با نفوذ بالا دارد که احتمال تشخیص خطا در آنها پایین است. برای حفظ امنیت شبکه و شناسایی اینگونه حملات، وجود سیستم های تشخیص داده بد قوی الزامی است. در صورتی که خطاها متعلق به اندازه گیری های حساس و نقاط نفوذ (LP) نباشند، حذف آنها به منظور تخمین دقیق مشکلی ایجاد نمی کند؛ با این حال، اگر داده بد به اندازه گیری های موجود

تلاش می‌کند نقاطی از سیستم را دستکاری و به آن حمله کند که احتمال تشخیص آن برای اپراتور سیستم، ضعیف باشد؛ بنابراین، حمله‌کننده باید در هر سیستمی، نقاط با قابلیت نفوذ بالا را مشخص کند تا حمله موثری صورت دهد.

بر اساس این، در فرآیند تخمین حالت در ماتریس ژاکوبین H ، هر سطر از این ماتریس با نشان داده می‌شود که در فضای n بُعدی قرار دارد و به آن، فضای ضرایب گفته می‌شود. در واقع هر نقطه، یک نقطه $(n+1)$ بُعدی در فضای ضرایب تعریف می‌کند که با سطرهای ماتریس H رسم شده‌اند. اگر ای، فاصله زیادی از سایر سطرهای ماتریس H داشته باشد، به آن نقطه، نقطه نفوذ (LP) گفته می‌شود و اندازه‌گیری متناظر با آن سطر، اندازه‌گیری نفوذ نامیده می‌شود. در صورتی که مقدار فاصله از سایر سطرهای ماتریس H خیلی بیشتر باشد، نقطه مذکور، نقطه‌ای با نفوذ بالا ($HLP^{(1)}$) و در صورتی که این میزان فاصله خیلی کمتر باشد، نقطه مذکور، نقطه‌ای با نفوذ پایین ($LLP^{(1)}$) نامیده می‌شود. اندازه‌گیری‌های متناظر با این نقاط به ترتیب اندازه‌گیری با نفوذ بالا ($HLM^{(2)}$) و اندازه‌گیری با نفوذ پایین ($LLM^{(4)}$) گفته می‌شوند [۱۹]، [۳]. مقدار نفوذ، میزان فاصله هر سطر از ماتریس H را نسبت به سایر سطرهای ماتریس H می‌سنجد. ویژگی خاص این اندازه‌گیری‌ها، این است که باقیمانده متناظر با آنها حتی در صورتی که به مقدار خطای زیادی آلوده باشند، بسیار کوچک است [۲۰]؛ بنابراین، مهاجم تلاش می‌کند نقاطی را دستکاری کند که احتمال تشخیص آن ضعیف باشد. به عبارت دیگر، مطلوب است تا به نقاط HLM ها حمله کند.

با توجه به اینکه مقدار باقیمانده متناظر با این اندازه‌گیری‌ها کوچک است و اساس تشخیص داده‌های بد نیز بر مبنای باقیمانده‌ها است، باعث گمراه شدن اپراتور در مرکز کنترل می‌شود. بر این مبنای، روش‌های تشخیص مبتنی بر باقیمانده به‌تنهایی قادر به تشخیص و شناسایی LP‌های آلوده به خطا نیستند و باید از روش‌های قوی برای تشخیص داده بد در این اندازه‌گیری‌ها استفاده کرد [۲۰]. عوامل زیر به شکل‌گیری LP منجر می‌شوند [۳]:

بر اساس بردار حالت اشتباه است. در مراجع [۱۶] و [۱۷] به بیان استراتژی‌های مختلف حمله پرداخته شده است.

رایج‌ترین روش تخمین حالت‌های شبکه، استفاده از الگوریتم تکراری حداقل مربعات وزندار ($WLS^{(1)}$) است و تابع هدف آن به صورت رابطه زیر بیان می‌شود:

$$\min J(x) = [z - h(x)]^T R^{-1} [z - h(x)] \quad (3)$$

که R و به ترتیب بیان‌کننده ماتریس کوواریانس خطای اندازه‌گیری (I ماتریس یکه است) و ماتریس قطری ضرایب وزنی هستند. روابط مربوط به محاسبه توان‌های اکتیو و راکتیو در [۱۸] آمده‌اند. متغیرهای حالت تخمین زده شده با شامل نشان داده و به صورت رابطه زیر محاسبه می‌شود:

$$\hat{x} = (H^T R^{-1} H)^T H^T R^{-1} z \quad (4)$$

با استفاده از حالت‌های تخمینی، بردار اندازه‌گیری‌های تخمین زده شده با نمایش داده و به صورت زیر تعریف می‌شود:

$$\hat{z} = H(H^T R^{-1} H)^{-1} H^T R^{-1} z = Kz \quad (5)$$

که K ماتریس نفوذ بالا نامیده می‌شود. مقادیر قطری بزرگ این ماتریس، متناظر با اندازه‌گیری‌هایی است که نفوذ و اهمیت زیادی دارند و تأثیر بیشتری روی حالت‌های تخمین زده شده دارند [۱۹].

اساس روش‌های BDD بر مبنای تحلیل مقدار باقیمانده است و به صورت زیر بیان می‌شود:

$$r_{bad} = z_{bad} - \hat{z}_{bad} = z + a - h(\hat{x} + c) \quad (6)$$

به منظور تشخیص وجود داده بد، مقدار باقیمانده با مقدار آستانه از پیش تعیین شده مطابق با تجربیات مقایسه می‌شود. در صورتی که مقدار باقیمانده از مقدار آستانه تجاوز کند، بیان‌کننده وجود داده بد تزریق شده به پارامترهای شبکه است [۱۲].

۳- نقاط نفوذ مؤثر برای حمله

مطابق با مدل حمله بیان‌شده در بخش قبلی، مهاجم

HLM وجود داشته باشد، ممکن است بعضی از LLMها به صورت اشتباه، HLM در نظر گرفته شوند؛ به این اثر swamping گفته می‌شود [۲۳].

۴- روش تشخیص نقاط با نفوذ بالا در حمله

در تجزیه و تحلیل مدل تخمین حالت، لازم است مجموعه مقادیر ماتریس H تعیین شوند که تأثیر زیادی بر برازش مدل دارند. در مجموعه اندازه‌گیری‌ها با وجود HLP به دلیل وجود دو پدیده $masking$ و $swamping$ ، در صورتی که نقاط به درستی تشخیص داده نشوند، به نتایج اشتباه در برازش مدل تخمین حالت منجر خواهند شد؛ بنابراین، می‌باید قبل از اجرای هر گونه اقدامی، مکان HLMها تشخیص داده شود و تأثیر آن بر مدل ارزیابی شود. مؤلفه‌های قطری ماتریس K و مقدار باقیمانده متناظر با اندازه‌گیری‌ها، شواهد موردنیاز برای ردیابی اندازه‌گیری‌های مهم را فراهم می‌کنند؛ اما استفاده از هر کدام از آنها به تنهایی مؤثر نخواهد بود. بدین سبب، بهتر است از ترکیب آنها استفاده شود. با توجه به اینکه تا کنون تأثیر این دو پدیده در مدل‌سازی تخمین حالت در نظر گرفته نشده است، سبب ایجاد انگیزه به منظور بررسی آن در این مقاله آمده است.

۴-۱- الگوریتم پتانسیل تعمیم‌یافته و مطمئن (DRGP)

زمانی که مجموعه اندازه‌گیری‌ها شامل بیش از یک نقطه HLP باشند، حذف یک یا چند اندازه‌گیری از مجموعه باعث می‌شود اندازه‌گیری‌های دیگری به اشتباه با نفوذ بالا ظاهر شوند. عکس این قضیه نیز برقرار است. در این مقاله به منظور جلوگیری از تشخیص اشتباه اندازه‌گیری‌ها از یک رویکرد قوی و تشخیصی استفاده می‌شود. ابتدا با استفاده از رویکرد قوی، نقاط با نفوذ بالا شناسایی و حدس زده می‌شوند و رویکرد تشخیصی حدس فوق را تأیید می‌کند. شناسایی LP براساس فاصله هر نقطه از مرکز نقاطی است که توده ابر مانند تشکیل داده‌اند. محاسبه مقدار فاصله براساس مطالعات آماری است که بتوان مرکز و ماتریس کوواریانس توده ابرمانند را محاسبه کرد. به این منظور از

۱- اندازه‌گیری‌های توان تزریقی روی باس‌هایی قرار گرفته باشند که شاخه‌های بیشتری در مقایسه با سایر باس‌ها به آن وصل باشند. به عبارت دیگر، مؤلفه‌های غیر صفر بیشتری در سطرهای ماتریس ژاکوبین H وجود داشته باشد.
 ۲- اندازه‌گیری‌های توان تزریقی روی باس‌هایی قرار گرفته باشند که شاخه‌های متصل به آن، دارای امیدانس بسیار متفاوت نسبت به سایر شاخه‌ها باشند.
 ۳- اندازه‌گیری‌های توان انتقالی روی شاخه‌ای قرار گرفته باشند که امیدانس آن نسبت به سایر شاخه‌ها خیلی متفاوت باشد.
 ۴- وزن اختصاص داده شده به یک اندازه‌گیری نسبتاً بزرگ باشد.

در تجزیه و تحلیل ماتریس H ، همیشه یک یا چند اندازه‌گیری وجود دارند که بر حل نهایی، بیشتر از اندازه‌گیری‌های دیگر تأثیر می‌گذارند. نقاطی که مقدار متغیر پاسخ آنها (یعنی مقدار اندازه‌گیری تخمین زده شده) دور از بقیه نقاط قرار گرفته باشد، نقاط خارج از خط^{۱۰} (یعنی اندازه‌گیری که حاوی داده بد است) نامیده می‌شوند [۲۰]. نقطه LP ای که اندازه‌گیری یا سطر متناظر با آن در ماتریس H ، آلوده به خطا باشد، نقطه نفوذ بد و نقطه LP ای که عاری از خطا باشد، نقطه نفوذ خوب نامیده می‌شود [۱۹]. در مراجع [۲۱، ۲۲] به بیان روش‌هایی از جمله مؤلفه‌های قطری ماتریس نفوذ بالا (K)، فاصله مهلانویس اندازه‌گیری‌ها و پردازش تصویری به منظور شناسایی LP پرداخته شده است. اگرچه در مقالات متعدد به بیان روش‌هایی برای شناسایی نقاط نفوذ پرداخته‌اند، به تأثیر وجود دو پدیده $masking$ و $swamping$ اشاره‌ای نشده است.

۳-۱- پدیده $masking$ و $swamping$

زمانی که مجموعه اندازه‌گیری‌ها شامل بیش از یک نقطه HLP باشند، حذف یک یا چند اندازه‌گیری از مجموعه باعث می‌شود اندازه‌گیری‌های دیگری با نفوذ بالا ظاهر شوند؛ در حالی که این اندازه‌گیری‌ها از همان ابتدا مشخص نبود نفوذ بالایی دارند. در واقع، HLPها LLP در نظر گرفته شده‌اند. به این اثر پوشش یا $masking$ گفته می‌شود. در اندازه‌گیری‌هایی که بیش از یک اندازه‌گیری

اندازه‌گیری‌هایی با اهمیت بالا باشند. مقدار پتانسیل تعمیم‌یافته برای مجموعه اندازه‌گیری‌های قرارگرفته در هر دو دسته D و R طبق رابطه زیر محاسبه می‌شود [۱۹]:

$$pot_{ii}^* = \begin{cases} \frac{K_{ii}^{-(D)}}{1 - K_{ii}^{-(D)}} & \forall i \in R \\ K_{ii}^{-(D)} & \forall i \in D \end{cases} \quad (10)$$

که pot_{ii}^* بیان‌کننده مقدار پتانسیل تعمیم‌یافته و مطمئن است. مقدار $cut-off$ برای مقایسه مقدار پتانسیل تعمیم‌یافته از رابطه زیر محاسبه می‌شود:

$$cut-off = Median(pot_{ii}^*) + cMAD(pot_{ii}^*) \quad (11)$$

مقدار ثابت c در این معادله برابر با ۳ در نظر گرفته شده است. با محاسبه مقدار pot برای هر دو دسته از اندازه‌گیری‌ها، لازم است مقدار پتانسیل متناظر با اندازه‌گیری‌های دسته D با مقدار $cut-off$ رابطه (۱۱) مقایسه شود. در صورتی که همه اندازه‌گیری‌های موجود در دسته D مقدار pot متناظرشان از مقدار $cut-off$ بزرگ‌تر باشد، HLP‌ها تعیین می‌شوند؛ در غیر این صورت، باید آن اندازه‌گیری که کمترین مقدار پتانسیل را دارد، به دسته R منتقل شود و مجدداً مقدار pot برای هر دو دسته جدید D و R محاسبه شود. این فرآیند تا زمانی ادامه می‌یابد که همه اندازه‌گیری‌های دسته D ، مقدار pot بزرگ‌تری از مقدار $cut-off$ داشته باشند. مراحل اجرای الگوریتم DRGP به شرح زیر است:

۱- مقدار RMD براساس تخمین‌گر MVE محاسبه می‌شود.

۲- با مقایسه مقادیر RMD اندازه‌گیری‌ها با مقدار $cut-off$ رابطه (۸)، اندازه‌گیری‌ها در دو گروه D و R دسته‌بندی می‌شوند.

۳- مقدار pot برای اندازه‌گیری‌های هر دو دسته D و R محاسبه و با مقدار $cut-off$ رابطه (۱۱) مقایسه می‌شود. عمل مقایسه و انتقال اندازه‌گیری دسته D که به‌اشتباه به‌عنوان HLP شناسایی شده باشد، به دسته R تا زمانی که

شاخص فاصله قوی مهلانویس ($RMD^{(1)}$) (به‌منظور شناسایی HLP‌ها استفاده می‌شود. شاخص RMD با رابطه زیر تعریف می‌شود [۲۴]:

$$RMD_i = \sqrt{[H_i - \bar{H}][C(H)]^{-1}[H_i - \bar{H}]^T} \quad (7)$$

که H_i بیان‌کننده نامین سطر از ماتریس H ، \bar{H} بیان‌کننده مرکز بیضی با حداقل حجم ($MVE^{(1)}$) است که L نقطه از تعداد m نقطه را می‌پوشاند و $C(H)$ ماتریس کوواریانس است. محاسبه \bar{H} و $C(H)$ با روش‌های معمول میانگین حسابی و ماتریس کوواریانس دقیق نیست و قادر به تشخیص HLP‌های واقعی نیستند؛ بنابراین، می‌باید از روش MVE استفاده کرد. به‌منظور مطالعه دقیق روش MVE به مقاله [۲۵] مراجعه شود. پس از محاسبه مقدار بردار مرکز و ماتریس کوواریانس بیضی با حداقل حجم، مقدار RMD برای تمام اندازه‌گیری‌های موجود محاسبه می‌شود. مقدار $cut-off$ برای مقایسه مقادیر RMD اندازه‌گیری‌ها طبق رابطه زیر تعریف می‌شود:

$$cut-off = Median(RMD_i) + cMAD(RMD_i) \quad (8)$$

که $Median$ مقدار میانه است و مقدار ثابت c برابر با ۲ یا ۳ در نظر گرفته می‌شود. مقدار انحراف مطلق میانه ($MAD^{(1)}$) مطابق با رابطه زیر محاسبه می‌شود.

$$MAD(x) = Median \left| \frac{x - Median(x)}{0.6745} \right| \quad (9)$$

با محاسبه مقدار RMD، آن دسته از اندازه‌گیری‌هایی که مقدار RMD متناظر با آنها از مقدار $cut-off$ بیشتر باشد، در دسته‌ای به اسم D قرار خواهند گرفت و از مجموعه اصلی حذف خواهند شد. اندازه‌گیری‌های باقیمانده در دسته R قرار می‌گیرند. در مرحله بعد لازم است مقدار پتانسیل تعمیم‌یافته (pot) برای هر دو دسته اندازه‌گیری‌ها محاسبه شود. در صورتی که اندازه‌گیری که به اشتباه به‌عنوان اندازه‌گیری HLP شناخته شده از دسته D حذف می‌شود و به دسته R اضافه می‌شود، مجدداً، فرآیند تخمین حالت با اندازه‌گیری‌های موجود در دسته R اجرا می‌شود. این روند تا زمانی ادامه دارد که همه اندازه‌گیری‌های دسته D ،

اندازه‌گیری‌های LLM در ناحیه پایین منحنی، اندازه‌گیری‌های HLM حاوی داده غلط، بسته به علامتشان در ناحیه بالا و در سمت راست یا چپ منحنی و اندازه‌گیری‌های LLM حاوی داده غلط، بسته به علامتشان در ناحیه پایین و در سمت راست یا چپ منحنی قرار می‌گیرند؛ بنابراین، با این روش، نقاط HLP و همچنین، نقاط آلوده به خطا شناسایی می‌شوند.

۵- الگوریتم روش پیشنهادی

براساس مطالب ارائه‌شده در بخش‌های ۲ تا ۴، فلوجارت مدل‌سازی حمله و روش پیشنهادی تشخیص BDI در شکل (۱) نشان داده شده است و مراحل اجرای الگوریتم به شرح زیرند:

گام ۱: در این مرحله برای مدل‌سازی حمله BDI، به تعدادی از اندازه‌گیری‌های موجود در شبکه داده‌هایی تزریق می‌شود.

گام ۲: به منظور تخمین متغیرهای حالت شبکه شامل اندازه و فاز ولتاژ باس‌ها از روش تخمین حداقل مربعات وزندار استفاده می‌شود.

گام ۳: در این مرحله مقدار RMD محاسبه و با مقدار $cut-off$ رابطه (۸) مقایسه می‌شود. اندازه‌گیری‌هایی که مقدار RMD آنها از مقدار $cut-off$ بزرگ‌تر باشد، در دسته D و سایر اندازه‌گیری‌ها در دسته R قرار می‌گیرند.

گام ۴: در این مرحله مقدار pot مطابق با رابطه (۱۰) محاسبه می‌شود. سپس مقدار pot اندازه‌گیری‌های دسته D با مقدار $cut-off$ رابطه (۱۱) مقایسه می‌شود. در صورتی که همه اندازه‌گیری‌های دسته D مقدار pot بزرگ‌تری از مقدار $cut-off$ داشته باشند، HLMها شناسایی می‌شوند. در غیر این صورت باید اندازه‌گیری با کمترین مقدار پتانسیل از دسته D حذف و به دسته R بازگردانده شود. این فرآیند تا زمانی ادامه می‌یابد که همه اندازه‌گیری‌های دسته D، مقدار pot بزرگ‌تر از مقدار $cut-off$ داشته باشند.

گام ۵: پس از شناسایی HLMها، مقدار GSR اندازه‌گیری‌ها مطابق با رابطه (۱۲) محاسبه و با عدد ۳ مقایسه می‌شود. اندازه‌گیری‌هایی که مقدار GSR آنها از عدد

همه اندازه‌گیری‌های موجود در دسته D مقدار pot بزرگ‌تری از مقدار $cut-off$ داشته باشند، ادامه خواهد داشت.

۴-۲- شناسایی داده بد

اندازه‌گیری‌های موجود در شبکه می‌تواند به آسانی با اهداف مختلف توسط مهاجم سایبری دستکاری شوند. همان‌طور که بیان شد مقدار باقیمانده در HLMها تقریباً نزدیک به صفر است و بسیاری از تخمین‌گرها از جمله تخمین‌گر LAV قادر به تشخیص داده بد در HLMها نیستند. سایر تخمین‌گرها از جمله LMS، LTS و RLS محاسبات بسیار پیچیده‌ای دارند؛ بنابراین، پس از شناسایی دسته‌بندی HLM و LLM لازم است وجود داده بد در اندازه‌گیری‌ها بررسی و تشخیص داده شود. با توجه به اینکه باقیمانده‌ها تابعی از مقدار نفوذ هستند، باید شناسایی HLPها و تشخیص داده بد در LPها با هم ترکیب شود و به صورت هم‌زمان اتفاق بیفتد؛ در غیر این صورت، به نتایج اشتباه منجر خواهد شد. برای تشخیص داده بد در کمیت‌های اندازه‌گیری‌شده از روش باقیمانده تعمیم‌یافته (GSR^{۱۹}) استفاده می‌شود. در این صورت وجود داده‌های غلط تزریق‌شده در دو دسته D و R به‌طور مجزا تشخیص داده و به صورت زیر محاسبه می‌شود:

$$r_{st,i}^* = \begin{cases} \frac{r_i^{-(D)}}{\hat{\sigma}_{R-i} \sqrt{1 - K_{ii}^{-(D)}}} & \forall i \in R \\ \frac{r_i^{-(D)}}{\hat{\sigma}_R \sqrt{1 + K_{ii}^{-(D)}}} & \forall i \in D \end{cases} \quad (12)$$

که $r_i^{-(D)}$ مقدار باقیمانده اندازه‌گیری نام با استفاده از مجموعه اندازه‌گیری‌های دسته D است. همچنین، $K_{ii}^{-(D)}$ مقدار مؤلفه قطری ماتریس $K^{-(D)}$ و $\hat{\sigma}^2$ تخمین حداقل مربعات واریانس است.

باقیمانده تعمیم‌یافته با مقدار آستانه برابر با ۳ مقایسه می‌شود. پس از آنکه مقدار DRGP و GSR محاسبه شوند، منحنی پتانسیل تعمیم‌یافته و مطمئن باقیمانده تعمیم‌یافته (DRGP-GSR) رسم می‌شود. در منحنی DRGP-GSR، اندازه‌گیری‌های HLM در ناحیه بالای منحنی،

۳ بزرگ‌تر باشد، حاوی داده جعلی‌اند و اندازه‌گیری داده بد شناخته می‌شوند.

گام ۶: در مرحله آخر، منحنی DRGP-GSR ترسیم می‌شود. اندازه‌گیری‌های LLM و دارای GSR کوچک در اطراف مبدأ قرار خواهند گرفت. همچنین، HLM در ناحیه بالای منحنی قرار می‌گیرند.

۶- نتایج شبیه‌سازی

۶-۱- شبکه‌های نمونه

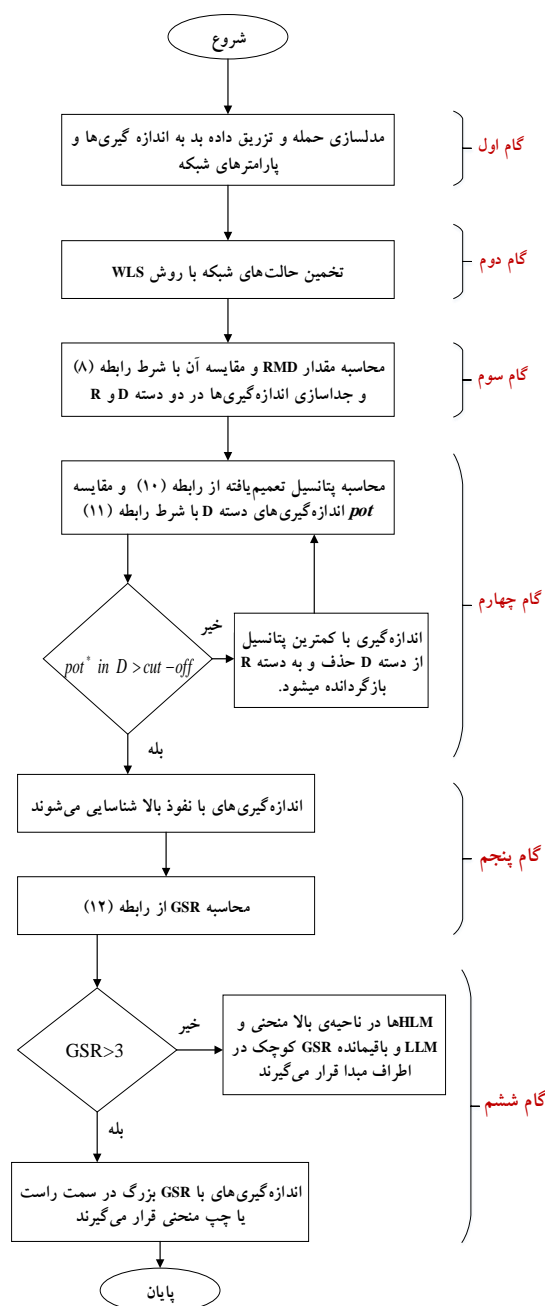
روش تشخیص داده بد پیشنهادشده بر شبکه‌های استاندارد ۱۴ و ۱۲۳ باسه IEEE پیاده‌سازی شده است. شبیه‌سازی الگوریتم‌های موجود با نرم‌افزارهای MATLAB و RStudio انجام شده است. اطلاعات بار و پارامترهای شبکه ۱۴ و ۱۲۳ باسه به ترتیب در [۲۶]، [۲۷] و [۲۸] موجودند. شماتیک شبکه ۱۴ باسه در شکل (۲) نشان داده شده است. مقادیر اندازه‌گیری‌ها با اضافه کردن نویز تصادفی نرمال با میانگین صفر و انحراف استاندارد ۰/۰۱ به نتایج پخش بار AC تولید شده‌اند. فرض شده است اطلاعات از ادوات اندازه‌گیری معمولی حاصل شده است. سناریوهای مختلفی برای دستکاری کردن اندازه‌گیری‌ها و پارامترهای شبکه برای بررسی کارایی روش پیشنهاد شده تعریف شده‌اند.

۶-۲- سناریو اول: دستکاری هم‌زمان

اندازه‌گیری‌ها و پارامترهای شبکه ۱۴ باسه

IEEE توسط مهاجم

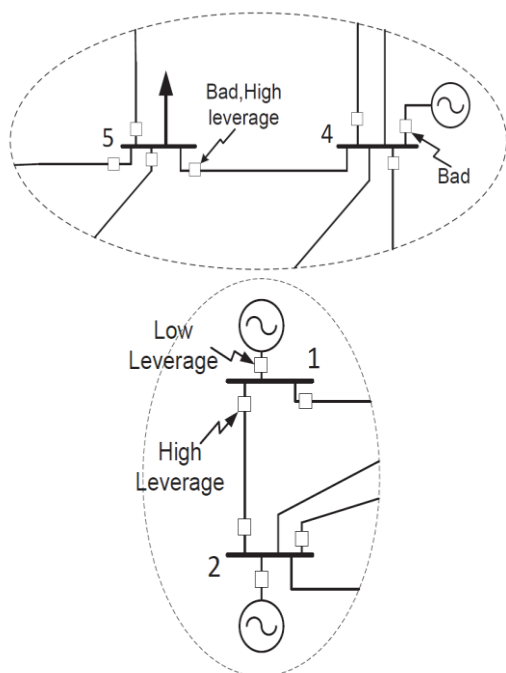
در سناریو اول فرض می‌شود مهاجم به اندازه‌گیری‌های توان اکتیو و راکتیو و همچنین، پارامترهای شبکه دسترسی پیدا می‌کند و داده‌های جعلی به آنها تزریق می‌کند. نفوذ به پارامترهای شبکه (راکتانس خطوط) به طراحی حمله دقیق نیاز دارد که به صرف هزینه و زمان زیادی منجر می‌شود. پارامترهای اندازه‌گیری‌شده شبکه ۱۴ باسه در جدول (۱) آورده شده‌اند. درخور ذکر است لازمه پیاده‌سازی روش پیشنهادی بر روی شبکه‌های واقعی، وجود تعداد کافی ادوات اندازه‌گیری برای رؤیت‌پذیری شبکه است. با توجه به آنکه دسترسی مهاجم به داده‌های مرکز کنترل بسیار سخت و شاید بتوان گفت در عمل امکان‌پذیر نیست، برای بررسی توانایی روش پیشنهادی فرض شده است امکان



شکل (۱): فلوچارت الگوریتم پیشنهادی


تزریق خطا به چنین اندازه‌گیری‌هایی، تشخیص داده بد در آنها دشوار خواهد بود. شماتیک این نقاط در شکل (۳) نشان داده شده است. در جدول (۱) پارامترها و اندازه‌گیری‌های مورد حمله و میزان خطای تزریقی به آنها آورده شده‌اند.

پس از تزریق خطا به پارامترها و مقادیر اندازه‌گیری‌ها و اجرای فرآیند تخمین حالت‌های شبکه، باید اندازه‌گیری‌های آلوده به خطا شناسایی شوند. در این راستا تلاش بر جداسازی و دسته‌بندی اندازه‌گیری‌های HLM و LLM است. به منظور شناسایی HLMها، ابتدا باید مقدار RMD متناظر با هر یک از اندازه‌گیری‌ها محاسبه شود که این نتایج در جدول (۲) آمده‌اند. اندازه‌گیری‌هایی که مقدار RMD بزرگ‌تری از مقدار *cut-off* دارند، به‌عنوان HLM حدس زده می‌شوند و در دسته D قرار خواهند گرفت. با توجه به مقدار RMD فاصله نسبتاً زیاد اندازه‌گیری‌های P_{e-4} ، P_4 ، P_1 و Q_{1-2} نسبت به بقیه اندازه‌گیری‌ها مشهود و نمایان است. چون در روش RMD ممکن است برخی از اندازه‌گیری‌ها که اهمیت چندانی ندارند، به اشتباه به‌عنوان اندازه‌گیری دارای اهمیت بالا شناخته شوند و بالعکس، لازم است با اجرای الگوریتم DRGP از شناسایی نوع اندازه‌گیری‌ها مطمئن شد.



شکل (۳): شماتیک نقاط HLP و LLP شبکه ۱۴ باسه IEEE

دسترسی مهاجم به مرکز کنترل فراهم است.



شکل (۲): شماتیک شبکه ۱۴ باسه IEEE

جدول (۱): مقدار اندازه‌گیری‌ها و پارامترهای دستکاری شده در

شبکه ۱۴ باسه IEEE


مقدار اندازه‌گیری / پارامتر پس از حمله (pu)	مقدار اولیه اندازه‌گیری / پارامترها (pu)	اندازه‌گیری / پارامترهای مورد حمله
۰/۶۶۵۷	۰/۶۱۵۷	P_{e-4}
۳/۱۶۵۳	۲/۳۱۵۳	P_1
-۰/۵۲۲۷	-۰/۴۷۷۲	P_4
۰/۰۴۹۱۷	۰/۰۵۰۱	x_{1-2}
۰/۲۲۲۹۴	۰/۲۲۲۸	x_{1-6}
۰/۲۰۸۱۲	۰/۲۰۷۱	x_{2-7}

تلاش مهاجم برای دستکاری کردن اندازه‌گیری‌ها، ایجاد نقاطی با نفوذ بالا و تزریق داده‌های اشتباه به این دسته از اندازه‌گیری‌ها است. به باس چهارم این شبکه، پنج شاخه متصل است که نسبت به سایر باس‌ها تعداد شاخه‌های بیشتری به این باس متصل است. مقدار راکتانس شاخه‌های متصل به باس یک نسبت به راکتانس سایر باس‌ها کمتر است و راکتانس شاخه متصل بین باس چهار و پنج نیز مقدار کوچکی دارد. همچنین، کاهش مقدار راکتانس شاخه‌های مرتبط با این باس‌ها باعث می‌شود اندازه‌گیری‌های مربوط به این باس‌ها و شاخه‌ها به‌عنوان اندازه‌گیری‌های با نفوذ بالا شناسایی شوند؛ بنابراین، با

جدول (۲): نتایج شبیه‌سازی در سناریو اول برای شبکه ۱۴ باسه IEEE

ردیف	اندازه‌گیری	مقدار RMD (cut_off=۵/۴۲۴۸)	$K_{ii}^{-(D)}$	DRGP (cut-off= ۰/۸۷۶۷)	GSR (cut-off= ۳/۰)
۱	$P_{۲-۱}$	۴/۲۷۴۵	۰/۰۴۵۸	۰/۰۴۷۹	-۰/۸۴۹۵
۲	$P_{۳-۲}$	۵/۰۱۷۶	۰/۰۶۱۱	۰/۰۶۵۰	۱/۹۸۷۰
۳	$P_{۲-۴}$	۳/۹۱۰۷	۰/۲۴۳۹	۰/۳۲۲۵	-۰/۳۵۰
۴	$P_{۱-۵}$	۵/۷۱۷۱	۰/۰۷۲۰	۰/۰۷۷۷	-۱/۴۷۶۰
۵	$P_{۵-۲}$	۴/۱۰۸۰	۰/۳۲۷۶	۰/۴۸۷۳	۲/۵۸۲
۶	$P_{۵-۴}$	۱۶/۲۰۰	۱/۳۴۵۸	۱/۳۴۵۸	۵/۲۱۲
۷	$P_{۵-۶}$	۵/۲۴۲۶	۰/۳۶۰۶	۰/۵۶۴۲	-۰/۶۵۱
۸	$P_{۴-۷}$	۴/۹۴۰۷	۰/۰۹۶۳	۰/۱۰۶۵	-۱/۴۵۷
۹	$P_{۸-۷}$	۳/۶۴۴۸	۰/۲۶۵۷	۰/۳۶۱۷	-۱/۴۹۱
۱۰	$P_{۹-۷}$	۵/۲۳۶۸	۰/۲۷۴۴	۰/۳۷۸۰	-۰/۶۴۵۵
۱۱	$P_{۹-۱۰}$	۵/۱۳۵۹	۰/۳۶۷۷	۰/۵۸۱۳	-۰/۷۵۶۰
۱۲	$P_{۶-۱۱}$	۵/۲۴۱۲	۰/۳۰۷۷	۰/۴۴۴۳	-۱/۵۰۱۷
۱۳	$P_{۱۳-۶}$	۵/۲۴۲۱	۰/۴۲۸۷	۰/۷۵۰۲	۰/۴۲۵۵
۱۴	$P_{۱۰-۱۱}$	۵/۱۶۷۵	۰/۱۸۵۵	۰/۲۲۷۷	۰/۹۶۷۸
۱۵	$P_{۱۳-۱۴}$	۵/۲۳۰۹	۰/۲۳۱۵	۰/۳۰۱۱	-۱/۵۲۶۳
۱۶	$P_۱$	۴/۶۷۶۶	۰/۷۳۹	۰/۰۷۹۲	۵/۷۸۶۱
۱۷	$P_۴$	۲۸/۱۰	۰/۸۷۷۶	۰/۸۷۷۶	-۳/۹۳۶۷
۱۸	$P_۸$	۳/۶۴۴۸	۰/۰۸۸۰	۰/۰۹۶۶	-۰/۶۸۹۰
۱۹	$P_۱۰$	۵/۱۴۵۶	۰/۲۳۱۸	۰/۳۰۱۶	-۰/۱۸۶۴
۲۰	$P_{۱۲}$	۵/۲۰۲۷	۰/۲۱۸۱	۰/۲۷۸۸	۰/۸۲۶۴
۲۱	$P_{۱۴}$	۵/۲۴۰۳	۰/۳۲۴۸	۰/۴۸۱۰	-۲/۵۳۳
۲۲	$Q_{۱-۲}$	۲۵/۵۰۰	۲/۱۵۴۰	۲/۱۵۴۰	۲/۰۰۸
۲۳	$Q_{۵-۱}$	۵/۱۷۱۰	۰/۰۴۲۶	۰/۰۴۴۴	-۱/۸۷۸
۲۴	$Q_{۴-۳}$	۵/۲۳۴۸	۰/۲۱۶۰	۰/۲۷۵۵	-۲/۱۸۵
۲۵	$Q_{۷-۸}$	۵/۲۴۲۶	۰/۳۱۶	۰/۴۶۲۰	۲/۵۵۴۸
۲۶	$Q_{۹-۴}$	۴/۴۸۲۷	۰/۲۳۱۸	۰/۳۰۱۸	۰/۸۵۹۷
۲۷	$Q_{۱۰-۹}$	۴/۶۸۴۵	۰/۲۴۸۰	۰/۳۲۹۸	-۰/۱۶۴۳
۲۸	$Q_{۱۴-۹}$	۵/۲۴۲۷	۰/۳۰۴۸	۰/۴۳۸۵	۰/۶۴۲۰
۲۹	$Q_{۱۳-۱۲}$	۵/۲۴۲۰	۰/۲۲۴۰	۰/۲۸۸۷	-۱/۴۸۳۶
۳۰	$Q_۲$	۵/۲۴۰۸	۰/۴۴۹۷	۰/۸۱۷۵	-۱/۳۵۶۴
۳۱	$Q_۶$	۵/۲۴۲۶	۰/۰۱۹۸	۰/۰۲۰۱	۲/۱۱۵۳
۳۲	$Q_۷$	۵/۲۳۷۸	۰/۴۴۰۳	۰/۷۸۶۸	۰/۱۴۶۲
۳۳	$Q_{۱۱}$	۵/۲۴۲۷	۰/۱۷۶۹	۰/۲۱۵۰	۰/۱۰۴۶
۳۴	$Q_{۱۳}$	۵/۲۳۲۶	۰/۰۸۶۵	۰/۰۹۴۸	-۱/۸۵۴

باقیمانده کوچکی دارند. نقاطی که مورد حمله قرار گرفته‌اند، از این نقاط دورند و در نواحی پرتی قرار می‌گیرند.



شکل (۴): منحنی DRGP-GSR شبکه ۱۴ باسه IEEE در

سناریو اول

۶-۳- سناریو دوم: حمله به کمیت‌های

اندازه‌گیری شده در شبکه ۱۴ باسه IEEE

در این سناریو، بردار حمله با توزیع نرمال تصادفی ایجاد شده است و به مقدار اندازه‌گیری‌ها اضافه می‌شود. نتایج حاصل از مقدار RMD، DRGP و GSR در جدول (۳) آورده شده‌اند. نتایج حاصل از مقدار DRGP نشان می‌دهند اندازه‌گیری‌های P_{2-1} و P_1 اندازه‌گیری‌های با نفوذ بالا (HLM) شناخته شده‌اند؛ زیرا مقدار DRGP متناظر با آنها از مقدار $0/8643$ بزرگ‌تر است. نتایج حاصل از مقدار GSR نشان می‌دهند میزان خطای تزریق شده به اندازه‌گیری‌های P_{1-11} ، P_{13-14} ، Q_{e-1} و Q_6 درخور توجه است. مقدار GSR متناظر با این اندازه‌گیری‌ها از عدد ۳ بزرگ‌تر است؛ بنابراین، این اندازه‌گیری‌ها حاوی داده بد هستند. نمودار نقطه‌ای DRGP-GSR مربوط به سناریو دوم در شکل (۵) نشان داده شده است.

مشاهده می‌شود اندازه‌گیری‌های P_{2-1} و P_1 در ناحیه

مقدار مؤلفه‌های قطری ماتریس K و نتایج DRGP مربوط به اندازه‌گیری‌ها در جدول (۲) آورده شده است. مشاهده می‌شود مقدار DRGP مربوط به اندازه‌گیری‌های P_e ، P_1 و P_{2-1} از مقدار $0/8767$ بزرگ‌تر است و اندازه‌گیری HLM شناخته می‌شوند.

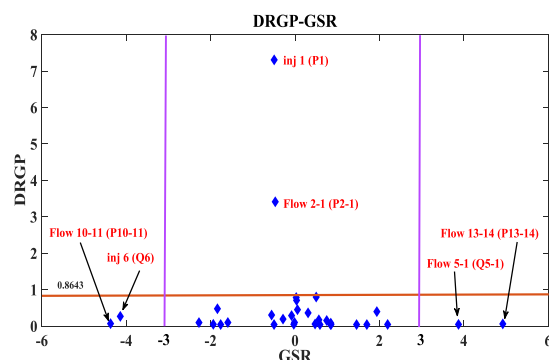
مطابق با نتایج نشان داده شده در جدول (۲)، اندازه‌گیری P_{1-5} دچار اثر swamping و به‌اشتباه، HLM شناخته شده است. همان‌گونه که گفته شد روش RMD ممکن است در تشخیص نوع اندازه‌گیری‌ها دچار اشتباه شود؛ بنابراین، با روش RMD نوع اندازه‌گیری‌ها حدس زده می‌شود و با الگوریتم DRGP از حدس زده شده اطمینان حاصل می‌شود. نتایج مقدار GSR محاسبه‌شده در جدول (۲) آورده شده‌اند. نتایج ذکرشده نشان می‌دهند مقدار باقیمانده تعمیم‌یافته سه اندازه‌گیری P_e ، P_1 و P_4 از مقدار ۳ بزرگ‌تر است. نتایج ذکرشده بیان‌کننده کارایی الگوریتم DRGP در شناسایی LPها است؛ در حالی که مقدار نفوذ (مؤلفه‌های قطری ماتریس K) قادر به شناسایی صحیح LPها نیست. همچنین، الگوریتم GSR به‌خوبی اندازه‌گیری‌های دستکاری‌شده را تشخیص می‌دهد.

با رسم نمودار نقطه‌ای DRGP-GSR در شکل (۴) مشاهده می‌شود اندازه‌گیری‌های با نفوذ بالا (HLM) شامل P_e ، P_4 و Q_{1-2} در ناحیه بالای منحنی و اندازه‌گیری‌های با نفوذ پایین (LLM) در ناحیه پایین منحنی قرار گرفته‌اند. اندازه‌گیری‌ها با نفوذ بالا و حاوی داده غلط (HLM, BD) شامل P_e ، P_4 در سمت بالا و با توجه به علامت مقدار GSR در سمت چپ یا راست منحنی واقع شده‌اند. همچنین، اندازه‌گیری‌های با نفوذ پایین و حاوی داده بد (LLM, BD) شامل P_1 ، با توجه به علامت GSR در سمت چپ یا راست منحنی قرار می‌گیرند. بیشتر نقاط در ناحیه مربوط به LLMها و نزدیک به مبدأ قرار دارند؛ زیرا مقدار

در نظر گرفته شده است.

با توجه به تعداد زیاد اندازه‌گیری‌ها از آوردن مقادیر DRGP, RMD و GSR همه اندازه‌گیری‌ها صرف‌نظر می‌شود و فقط مقادیر مربوط به اندازه‌گیری‌های مورد حمله در جدول (۴) آورده می‌شوند. منحنی نقطه‌ای DRGP-GSR شبکه ۱۲۳ باسه IEEE در شکل (۶) نشان داده شده است. مطابق با نتایج شبیه‌سازی اندازه‌گیری‌های P_{14} , P_{54} , P_{14-9} و P_{54-55} مقدار DRGP بزرگ‌تری از مقدار 0.8643 دارند و اندازه‌گیری‌های HLM شناخته می‌شوند. نتایج حاصل از مقدار GSR نشان می‌دهند اندازه‌گیری‌های P_{54} , P_{14} , P_{54-55} و P_{17} مقدار GSR بزرگ‌تری از مقدار ۳ دارند؛ بنابراین، این اندازه‌گیری‌ها حاوی داده بد هستند؛ زیرا میزان خطای تزریق‌شده به آنها شایان توجه بوده است. باوجود تزریق خطا به اندازه‌گیری P_{37} مقدار GSR متناظر با آن از مقدار ۳ کمتر است و علت عدم شناسایی آن به‌منزله اندازه‌گیری حاوی داده بد، تزریق خطا بسیار ناچیز است. همچنین، با توجه به مقدار DRGP متناظر با آن، اندازه‌گیری LLM است که اهمیت زیادی بر تخمین حالت شبکه ندارد. همچنین، اندازه‌گیری‌های آلوده به خطا شامل P_{54} و P_{55} چون اندازه‌گیری‌های با نفوذ بالا (HLM.BD) هستند، در ناحیه بالا و با توجه به علامت مقدار GSR در سمت راست منحنی قرار گرفته‌اند. اندازه‌گیری P_{14} از نوع اندازه‌گیری HLM است و با توجه به علامت منفی GSR متناظر با آن، در سمت بالا و چپ منحنی قرار گرفته است. اندازه‌گیری (P_{17}) چون اندازه‌گیری LLM و حاوی داده بد است، در ناحیه پایین و سمت راست منحنی قرار گرفته است.

بالای منحنی قرار گرفته‌اند. اندازه‌گیری‌های آلوده به خطا شامل اندازه‌گیری‌های P_{10-11} , P_{13-14} , P_{5-1} و Q_{6-1} است و چون اندازه‌گیری‌های با نفوذ پایین (LLM.BD) هستند، در ناحیه پایین منحنی قرار می‌گیرند. اندازه‌گیری‌های Q_{5-1} و P_{13-14} با توجه به مقدار مثبت GSR در سمت راست و اندازه‌گیری‌های P_{10-11} و Q_{6-1} با توجه به مقدار منفی GSR متناظرشان در سمت چپ منحنی قرار خواهند گرفت.



شکل (۵): منحنی DRGP-GSR شبکه ۱۴ باسه IEEE در

سناریو دوم

۶-۴- دستکاری هم‌زمان اندازه‌گیری‌ها و پارامترهای شبکه ۱۲۳ باسه IEEE توسط مهاجم

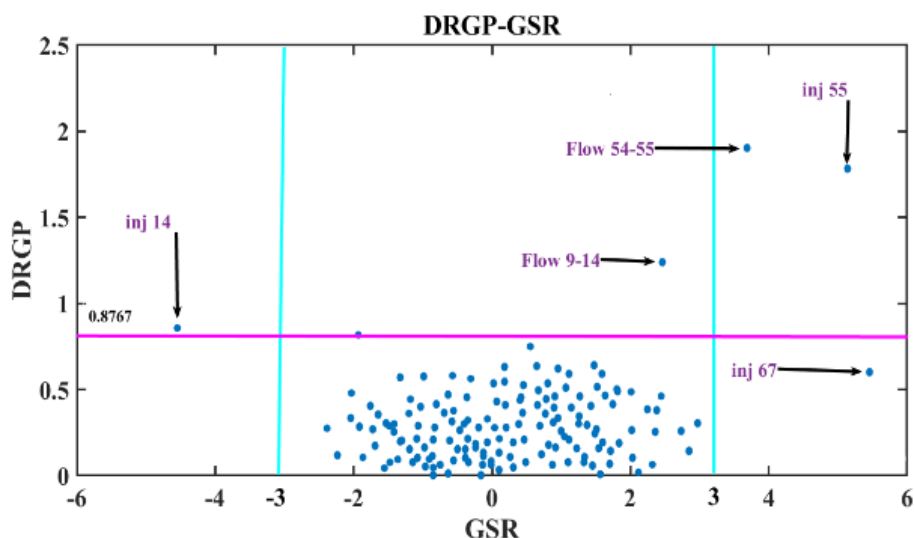
در این شبکه، مقادیر اندازه‌گیری‌ها با اضافه کردن نویز تصادفی نرمال با میانگین صفر و انحراف استاندارد 0.1 به نتایج پخش بار AC تولید شده‌اند. استراتژی حمله در این شبکه با افزودن خطاهای تصادفی به مقادیر اندازه‌گیری‌های توان تزریقی در باس‌های ۱۴، ۳۶، ۵۵ و $(P_{14}, P_{37}, P_{54}, P_{55})$ و اندازه‌گیری توان انتقالی از خط ۵۴ به ۵۵ (P_{54-55})

جدول (۳): نتایج شبیه‌سازی در سناریو دوم

ردیف	اندازه‌گیری	DRGP (cut_off=0.8643)	GSR (cut_off=3/0)
۱	P_{r-1}	۳/۴۱۳۳	-۰/۴۷۱۳۷
۲	P_{r-2}	۰/۷۸۵۸	۰/۰۲۵۲۵
۳	P_{r-3}	۰/۴۵۲۲	۰/۰۵۵۴۶
۴	P_{r-4}	۰/۷۹۹۳	۰/۴۹۹۰
۵	P_{r-5}	۰/۲۸۹۷	-۰/۰۸۴۴
۶	P_{r-6}	۰/۵۰۶۰	۱/۳۶۸۲
۷	P_{r-7}	۰/۳۰۵۱	-۰/۵۵۸۰
۸	P_{r-8}	۰/۱۵۵۱	۰/۷۴۸۴
۹	P_{r-9}	۰/۰۴۳۶۱	۱/۶۹۹۶
۱۰	P_{r-10}	۰/۱۷۳۸	۰/۵۶۲۰
۱۱	P_{r-11}	۰/۰۴۶۱۹	۲/۱۹۲۵
۱۲	P_{r-12}	۰/۰۵۱۰	۰/۸۳۷۷
۱۳	P_{r-13}	۰/۰۹۹۸	-۱/۵۹۴۷
۱۴	P_{r-14}	۰/۰۶۹۳۶	-۴/۳۷۴۸
۱۵	P_{r-15}	۰/۰۶۱۷۳	۴/۹۲۱۷
۱۶	P_r	۷/۳۰۷۹	-۰/۴۹۶۸
۱۷	P_s	۰/۳۶۳۸	۰/۳۰۶۴
۱۸	P_{s1}	۰/۰۴۳۶۱	۱/۴۵۶۳
۱۹	P_{s2}	۰/۰۵۸۳۰	۰/۴۷۲۵
۲۰	P_{s3}	۰/۰۵۰۸۶	-۱/۹۳۹۹
۲۱	P_{s4}	۰/۰۸۲۰	-۰/۸۴۵۰
۲۲	Q_{r-2}	۰/۱۰۱۵	-۰/۰۱۴۷۷
۲۳	Q_{s-1}	۰/۰۴۷۹۲	۳/۸۷۱۹
۲۴	Q_{s-2}	۰/۴۷۷۵	-۱/۸۴۲۰
۲۵	Q_{s-3}	۰/۳۹۹۱	۱/۹۳۶۶
۲۶	Q_{s-4}	۰/۰۴۳۴۸	۰/۸۴۹۵
۲۷	Q_{s-5}	۰/۷۰۷۶	۰/۰۳۳۸۲
۲۸	Q_{s-6}	۰/۰۹۷۶۹	-۲/۲۷۹۵
۲۹	Q_{s-7}	۰/۰۴۴۲۵	-۰/۴۹۹۸
۳۰	Q_r	۰/۱۹۴۰	-۰/۲۸۷۴
۳۱	Q_{s1}	۰/۲۶۸۲	-۴/۱۴۳۸
۳۲	Q_{s2}	۰/۰۴۳۶	۰/۵۸۷۸
۳۳	Q_{s3}	۰/۰۴۴۵	-۱/۷۶۴۹
۳۴	Q_{s4}	۰/۰۵۰۲۴	-۰/۰۳۱۳۸

جدول (۴): نتایج شبیه‌سازی بر شبکه ۱۲۳ باسه IEEE

اندازه‌گیری	DRGP (cut_off=۰/۸۷۶۷)	GSR (cut_off=۳/۰)
P_{14}	۰/۸۹۷۵	-۴/۸۶۵
P_{17}	۵/۴۷۶	۵/۲۳۶
P_{22}	۱/۸۹۸	۴/۵۷۶
P_{37}	۰/۷۶۵	۲/۰۵۶
P_{50-54}	۱/۸۵۷	۳/۶۸۸



شکل (۶): منحنی DRGP-GSR شبکه ۱۲۳ باسه IEEE

اندازه‌گیری‌ها به اشتباه تشخیص داده شوند؛ یعنی اندازه‌گیری HLM، به اشتباه اندازه‌گیری LLM شناخته شود و بالعکس. این در حالی است که الگوریتم DRGP با محاسبه مقدار پتانسیل متناظر با اندازه‌گیری‌های موجود در دو دسته D و R، شناسایی اشتباه اندازه‌گیری‌ها را با روش RMD اصلاح می‌کند؛ بنابراین، روش DRGP قابلیت تشخیص دقیق HLM ها را از LLM ها دارد.

۷-۲- مقایسه الگوریتم GSR با باقیمانده استیودنت شده داخلی در شبکه ۱۴ باسه IEEE

در رابطه با بررسی صحت و دقت الگوریتم BDD ارائه شده، نتایج حاصل از مقادیر GSR با روش باقیمانده استیودنت داخلی^{۲۰} مقایسه شده‌اند. نتایج مقادیر GSR و باقیمانده استیودنت شده داخلی در سناریو اول شبکه ۱۴ باسه در جدول (۵) آورده شده‌اند. با مشاهده نتایج ملاحظه می‌شود اندازه‌گیری P_{e-2} مقدار باقیمانده استیودنت شده داخلی آن از مقدار ۳ بزرگ‌تر است و به‌عنوان اندازه‌گیری حاوی داده بد شناسایی شده است؛ در حالی که مقدار GSR متناظر با این اندازه‌گیری از مقدار ۳ کوچک‌تر است. همچنین، روش باقیمانده استیودنت شده داخلی قادر به تشخیص اندازه‌گیری P_{e-4} به‌عنوان اندازه‌گیری حاوی داده بد نبوده است؛ بنابراین، روش باقیمانده استیودنت شده داخلی

۷-مقایسه نتایج روش پیشنهادی با سایر روش‌ها

به‌منظور بیان کارایی دقیق و بالای روش پیشنهادی، شناسایی اندازه‌گیری‌های HLM و LLM با استفاده از الگوریتم‌های DRGP و RMD بر شبکه ۱۴ باسه انجام شده است. همچنین، شناسایی اندازه‌گیری‌های حاوی داده بد با استفاده از الگوریتم GSR و روش باقیمانده استیودنت شده داخلی انجام شده است که در ادامه، نتایج تحلیل شده‌اند.

۷-۱- مقایسه الگوریتم DRGP با RMD در شبکه ۱۴ باسه IEEE

در مقایسه نتایج روش ارائه شده با سایر روش‌ها، از نتایج شبیه‌سازی جدول (۲) بر شبکه ۱۴ باسه مشاهده شد که الگوریتم DRGP به‌خوبی قابلیت تشخیص درست اندازه‌گیری‌های HLM را از اندازه‌گیری‌های LLM دارد؛ در حالی که روش‌های نفوذ (مقدار مؤلفه‌های قطری ماتریس K) و RMD به اثر *masking* و *swamping* آسیب‌پذیرند و قادر به تشخیص و جداسازی درست اندازه‌گیری‌های HLM و LLM نیستند. در روش مقدار نفوذ و RMD، ممکن است نوع

P_{9-7}	۱/۸۸۱	-۰/۶۴۵۵
P_{9-10}	۰/۹۴۳	-۰/۷۵۶۰
P_{7-11}	۰/۷۸۶	-۱/۵۰۱۷
P_{13-6}	۰/۱۸۷	۰/۴۲۵۵
P_{10-11}	۰/۶۷۸	۰/۹۶۷۸
P_{13-14}	۱/۳۴۲	-۱/۵۲۶۳
P_1	۳/۴۴۲	۵/۷۸۶۱
P_4	۰/۵۵۲	-۳/۹۳۶۷
P_8	۰/۶۷۴	-۰/۶۸۹۰
P_{10}	۰/۴۵۲	-۰/۱۸۶۴
P_{12}	۰/۱۲۳	۰/۸۲۶۴
P_{14}	۱/۲۶۵	-۲/۵۲۳
Q_{1-2}	۲/۵۷۶	۲/۰۰۸
Q_{5-1}	۲/۵۳۶	-۱/۸۷۸
Q_{4-3}	۱/۹۳۲	-۲/۱۸۵
Q_{7-8}	۱/۵۴۶	۲/۵۵۴۸
Q_{9-4}	۰/۳۸۷	۰/۸۵۹۷
Q_{10-9}	۰/۵۵۷	-۰/۱۶۴۳
Q_{14-9}	۰/۴۵۶	۰/۶۴۲۰
Q_{13-12}	۰/۱۱۵	-۱/۴۸۳۶
Q_2	۰/۵۶۷	-۱/۳۵۶۴
Q_6	۰/۲۵۷	۲/۱۱۵۳
Q_7	۲/۴۳۶	۰/۱۴۶۲
Q_{11}	۰/۶۷۵	۰/۱۰۴۶
Q_{13}	۰/۸۳۲	-۱/۸۵۴

نه تنها قادر به تشخیص درست اندازه‌گیری‌های آلوده به خطا نیست، ممکن است اندازه‌گیری مورد حمله قرار نگرفته را به‌منزله اندازه‌گیری آلوده به خطا شناسایی کند؛ اما روش GSR قادر به تشخیص صحیح اندازه‌گیری‌های آلوده به خطا است.

۸- نتیجه‌گیری

در این مقاله، روش جدیدی در شناسایی داده بد تزریق شده به اندازه‌گیری‌ها و پارامترهای شبکه ارائه شده است. در این روش، علاوه بر شناسایی اندازه‌گیری‌های با نفوذ بالا و پایین، اندازه‌گیری‌های آلوده به خطا و دستکاری شده مهاجم، به تفکیک هر نوع اندازه‌گیری تشخیص داده می‌شوند. نتایج شبیه‌سازی نشان می‌دهند احتمال تشخیص اشتباه اندازه‌گیری‌های دستکاری شده با جداسازی نوع اندازه‌گیری‌های HLM و LLM بسیار کاهش یافته است. در این صورت، حتی اگر مهاجم قادر به نفوذ به مرکز کنترل و دستکاری پارامترهای شبکه باشد، به گونه‌ای که سیستم تشخیص داده بد را دور بزند، الگوریتم‌های ارائه شده با قدرت بالا، اندازه‌گیری‌های دستکاری شده و آلوده به خطا را تشخیص می‌دهند. جداسازی اندازه‌گیری‌های با نفوذ بالا و تخمین حالت‌های شبکه با استفاده از اندازه‌گیری‌های با نفوذ پایین، امکان موفق شدن مهاجم را هرچند نقشه‌های بسیار دقیق را پیاده‌سازی کند، محدود خواهد کرد.

۹- مراجع

1. Liang, G., et al., *A review of false data injection attacks against modern power systems*. IEEE Transactions on Smart Grid, 2016. 8(4): p. 1630-1638.
2. KP, V.P. and J. Bapat. *Bad data detection in smart grid for AC model*. in *2014 Annual IEEE India Conference (INDICON)*. 2014. IEEE.
3. Tan, S., et al. *LPAttack: Leverage point attacks against state estimation in smart grid*. in *2014 IEEE Global Communications Conference*. 2014. IEEE.
4. Singh, S.K., et al., *Joint-transformation-based detection of false data injection attacks in smart grid*. IEEE Transactions on Industrial Informatics, 2017. 14(1): p. 89-97.
5. Li, S., Y. Yilmaz, and X. Wang, *Quickest detection of false data injection attack in wide-area smart grids*. IEEE Transactions on Smart Grid, 2014. 6(6): p. 2725-2735.
6. Liu, X., et al., *Modeling of local false data injection*

جدول (۵): مقایسه نتایج روش پیشنهادی با سایر روش‌ها

اندازه‌گیری	Internally studentized residual (cut-off= ۳/۰)	GSR (cut-off= ۳/۰)
P_{2-1}	۰/۷۹۸	-۰/۸۴۹۵
P_{3-2}	۱/۳۴۳	۱/۹۸۷۰
P_{7-4}	۰/۸۹۱	-۰/۳۵۰
P_{10-5}	۰/۵۳۲	-۱/۴۷۶۰
P_{5-2}	۳/۷۳۱	۲/۵۸۲
P_{5-4}	۳/۲۳۸	۵/۲۱۲
P_{5-6}	۱/۵۴۶	-۰/۶۵۱
P_{4-7}	۱/۲۸۷	-۱/۴۵۷
P_{8-7}	۰/۹۰۸	-۱/۴۹۱

- reconfiguration method for enhancing resilience of distribution systems considering the whole process of resiliency*. International Transactions on Electrical Energy Systems, 2020. 30(2): p. e12199.
18. Tran, N.N., et al., *Designing Constraint-Based False Data-Injection Attacks Against the Unbalanced Distribution Smart Grids*. IEEE Internet of Things Journal, 2021. 8(11): p. 9422-9435.
 19. Majumdar, A. and B.C. Pal, *Bad data detection in the context of leverage point attacks in modern power networks*. IEEE Transactions on Smart Grid, 2016. 9(3): p. 2042-2054.
 20. Habshah, M., M. Norazan, and A. Rahmatullah Imon, *The performance of diagnostic-robust generalized potentials for the identification of multiple high leverage points in linear regression*. Journal of Applied Statistics, 2009. 36(5): p. 507-520.
 21. Lim, H.A. and H. Midi, *Diagnostic Robust Generalized Potential based on Index Set Equality (DRGP (ISE)) for the identification of high leverage points in linear model*. Computational statistics, 2016. 31(3): p. 859-877.
 22. Chen, J. and A. Abur, *Placement of PMUs to enable bad data detection in state estimation*. IEEE Transactions on Power Systems, 2006. 21(4): p. 1608-1615.
 23. Rahmatullah Imon, A., *Identifying multiple influential observations in linear regression*. Journal of Applied statistics, 2005. 32(9): p. 929-946.
 24. Deka, D., R. Baldick, and S. Vishwanath, *Hidden attacks on power grid: optimal attack strategies and mitigation*. arXiv preprint arXiv:1401.3274, 2014.
 25. A. T. Koru, "Finding Minimum Volume Ellipsoid Enclosing N Points via Semi-Definite Programming," 2016..
 26. Power systems test case archive. "<http://www.ee.washington.edu/research/pstca/>.
 27. Group, D.T.F.W., *Distribution test feeders*. Available from: [ewh. ieee. org/soc/pes/dsacom/testfeeders/index. html](http://ewh.ieee.org/soc/pes/dsacom/testfeeders/index.html), 2010.
 28. Kersting, W.H., *Radial distribution test feeders*. IEEE Transactions on Power Systems, 1991. 6(3): p. 975-985.
 7. Bretas, A.S., N.G. Bretas, and B.E. Carvalho, *Further contributions to smart grids cyber-physical security as a malicious data attack: Proof and properties of the parameter error spreading out to the measurements and a relaxed correction model*. International Journal of Electrical Power & Energy Systems, 2019. 104: p. 43-51.
 8. Zhao, J. and L. Mili, *Vulnerability of the largest normalized residual statistical test to leverage points*. IEEE Transactions on Power Systems, 2018. 33(4): p. 4643-4646.
 9. Arvani, A. and V.S. Rao, *Detection and protection against intrusions on smart grid systems*. International Journal of Cyber-Security and Digital Forensics (IJCSDF), 2014. 3(1): p. 38-48.
 10. Li, B., et al., *Detecting false data injection attacks against power system state estimation with fast go-decomposition approach*. IEEE Transactions on Industrial Informatics, 2018. 15(5): p. 2892-2904.
 11. Drayer, E. and T. Routtenberg, *Detection of false data injection attacks in smart grids based on graph signal processing*. IEEE Systems Journal, 2019. 14(2): p. 1886-1896.
 12. Liu, Y., P. Ning, and M.K. Reiter, *False data injection attacks against state estimation in electric power grids*. ACM Transactions on Information and System Security (TISSEC), 2011. 14(1): p. 1-33.
 13. Pan, K., et al., *Cyber risk analysis of combined data attacks against power system state estimation*. IEEE Transactions on Smart Grid, 2018. 10(3): p. 3044-3056.
 14. Yang, Q., et al. *On a hierarchical false data injection attack on power system state estimation*. in *2011 IEEE Global Telecommunications Conference-GLOBECOM 2011*. 2011. IEEE.
 15. Deng, R., P. Zhuang, and H. Liang, *False data injection attacks against state estimation in power distribution systems*. IEEE Transactions on Smart Grid, 2018. 10(3): p. 2871-2881.
 16. Lakshminarayana, S., et al., *Data-driven false data injection attacks against power grids: A random matrix approach*. IEEE Transactions on Smart Grid, 2020. 12(1): p. 635-646.
 17. Wang, H., et al., *A novel planning attack*

¹ Phasor Measurement Unit

² Bad Data Injection

³ State Estimation

⁴ Bad Data Detection

⁵ Absolut Distance

⁶ Kullback-Leibler Distance

⁷ Diagnostic Robust Generalized Potential

⁸ High Leverage Point

⁹ Leverage Point

- ¹⁰ Weighted Least Square
- ¹¹ High Leverage Point
- ¹² Low Leverage Point
- ¹³ High Leverage Measurement
- ¹⁴ Low Leverage Measurement
- ¹⁵ Outlier
- ¹⁶ Robust Mahalanobis Distance (RMD)
- ¹⁷ Minimum Volume Ellipsoid
- ¹⁸ Median Absolut Deviation
- ¹⁹ Generalized Studentized Residual (GSR)
- ²⁰ Internally Studentized Residual

