

Bad Data Detection and Identification Using Artificial Neural Networks

Kafi Adira*

(Received 23 / 10 / 2024. Accepted 24 / 11 / 2024)

□ ABSTRACT □

This paper explores the capability of the artificial neural networks to detect and identify the single and multiple bad data which can be found within the measurements provided to energy management system centers. A reduced model for state estimation was developed in the MATLAB environment using NN-TOOL. A comparison of the single bad data detection and identification between the proposed state estimator and the Weighted Least Squares state estimator on IEEE 14-bus power systems is provided. The results show that the proposed model is more accurate and faster than the WLS state estimator. Furthermore, the proposed methodology is a great alternative to the conventional techniques and is therefore well suited for smart grid applications.

This research presents a different approach for handling bad data compared to the iterative and lengthy statistical methods used previously. It provides a streamlined model for the state estimator that allows for effective and reliable monitoring and operation of the power system with lower computational requirements and the implementation of this procedure in real time, which positively impacts the overall performance of the energy management system. Its main objective is to enhance the functioning of the electric power management system by utilizing artificial neural networks.

Typically, a state estimation is performed prior to the process of detecting, identifying, and excluding bad data, where the traditional state estimator relies on a set of redundant measurements to describe the system through a set of over-specified nonlinear equations, followed by a series of iterative numerical mathematical operations aimed at minimizing measurement errors until the optimal value of the system state variables is achieved. The theory of weighted least squares is one of the most commonly used methods for this purpose.

Keywords: Artificial Intelligent, Bad Data Detection and Identification, Smart Grid.

Copyright



:Tishreen University journal-Syria, The authors retain the copyright under a CC BY-NC-SA 04

*ماجستير - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

اكتشاف وتحديد البيانات السيئة باستخدام الشبكات العصبونية الاصطناعية

كافي عديرة*

(تاريخ الإيداع 23 / 10 / 2024. قُبِلَ للنشر في 24 / 11 / 2024)

□ ملخص □

يوضح هذا البحث قدرة الشبكات العصبونية الاصطناعية في اكتشاف وتحديد البيانات السيئة المفردة والمتعددة التي تتوافق مع القياسات الواردة إلى مراكز إدارة نظم الطاقة الكهربائية، حيث تم تطوير نموذج مختزل لمقيم حالة في بيئة ماتلاب باستخدام NN-toolbox، وتم اختبار هذا النموذج في اكتشاف وتحديد البيانات السيئة المفردة ومقارنة أدائه مع مقيم الحالة التقليدي الذي يعتمد معيار مربعات الفرق الأصغرية الموزونة. تمت الدراسة على نظام قدرة كهربائي نموذجي IEEE 14-bus power systems وأوضحت النتائج تفوق النموذج المقترح من حيث الدقة والسرعة مما يجعله أكثر ملاءمة للاستخدام في إدارة نظم القدرة الكهربائية الحديثة والشبكات الذكية. يقدم هذا البحث أسلوباً مختلفاً لمعالجة البيانات السيئة عن الطرق التكرارية والإحصائية المطولة المستخدمة سابقاً. ويوفر نموذجاً مختزلاً لمقيم الحالة يسمح بمراقبة نظام القدرة وتشغيله بطريقة فعالية وموثوقة بمتطلبات وعبء حسابي أقل وتنفيذ هذا الإجراء في الزمن الحقيقي وذلك ينعكس إيجاباً على عمل نظام إدارة الطاقة بالمجمل. ويهدف بشكل أساسي إلى تحسين عمل وظائف نظام إدارة القدرة الكهربائية باعتماد الشبكات العصبونية الاصطناعية. عادة ما يتم إجراء تقييم الحالة قبل عملية اكتشاف وتحديد البيانات السيئة واستبعادها، حيث يعتمد مقيم الحالة التقليدي على مجموعة من القياسات الفائضة لوصف النظام بجملة معادلات لا خطية فوق محددة ومن ثم إجراء سلسلة من العمليات الرياضية العددية التكرارية تهدف لتصغير أخطاء القياس حتى الوصول إلى القيمة المثلى لمتحولات حالة النظام، وتعتبر نظرية مربعات الفرق الأصغرية الموزونة من أشهر الطرق المستخدمة لأجل ذلك.

الكلمات المفتاحية: اكتشاف وتحديد البيانات السيئة، شبكات ذكية، الذكاء الاصطناعي



حقوق النشر : مجلة جامعة تشرين- سورية، يحتفظ المؤلفون بحقوق النشر بموجب الترخيص

CC BY-NC-SA 04

* Master- Faculty of Electrical and Mechanical Engineering- Tishreen University- Latakia- Syria.

مقدمة:

إن اكتشاف وتحديد البيانات السيئة الواردة إلى مراكز إدارة الطاقة الكهربائية يعتبر أمراً مهماً لضمان عمل برمجيات الإدارة بصورة دقيقة وموثوقة، حيث يتولى مقيم حالة النظام أداء هذه المهمة فمن المفروض أن يستطيع اكتشاف وتحديد الأخطاء الموجودة في القياسات الواردة واستبعادها إن كان ذلك ممكن.

هناك أنواع عديدة ومختلفة لأخطاء القياسات في نظم القدرة والتي تشمل: الأخطاء العشوائية الناتجة عن الدقة المحدودة لمعدات وأجهزة القياس والاتصال، والأخطاء الكبيرة يمكن أن تنتج عن انحرافات القياس أو خطأ توصيل المقاييس أو فشل نظام الاتصال وكذلك يمكن أن تنتج عن التشويش والتداخل مع نظم وأجهزة مجاورة.

إن احتواء البيانات الواردة إلى مقيم الحالة على أخطاء كبيرة يؤدي إلى عمله بشكل غير دقيق حيث يعطي صورة غير دقيقة عن حالة عمل نظام القدرة وهذا بدوره يقود إلى عمل باقي برامج الإدارة بشكل خاطئ وعدم ضمان التشغيل والتحكم الأمثل بنظام القدرة وبالتالي فإن اكتشاف وتحديد البيانات السيئة جزء مهم وحاسم من إجراء تقييم الحالة.

من أولى الطرق المستخدمة في اكتشاف وتحديد البيانات السيئة هي طريقة الحذف أو الاستبعاد Method by Elimination تم تطوير هذه الطريقة من قبل مؤسس نظرية تقييم الحالة (Schowppe 1970) وتعتمد هذه الطريقة على تحليل رواسب القياس وتتبع منهجية تكرارية [4-1]. لاحقاً تم تطوير طريقة أكثر فعالية في تحديد البيانات السيئة عرفت باختبار الفرض Hypothesis Testing حيث اعتمدت هذه الطريقة على تحليل أخطاء القياسات بدلاً من رواسب القياس وبالتالي كانت أكثر دقة، إذ أن خطأ القياس يرتبط بشكل مباشر بالقياس الموافق له [6-4]. وفي دراسات لاحقة تم التعامل مع مسألة معالجة البيانات السيئة بطرق مختلفة، إذ تم تحويلها إلى مسألة أمثلة، وكان من أهم النظريات المطروحة نظرية القرار Decision Theory وتعتمد هذه الطريقة على تشكيل شجرة القرار من أجل الحصول على كل القرارات الممكنة، ومن بين هذه القرارات يتم تشكيل مجموعة القرارات أو الحلول المناسبة حيث يعتبر القرار مناسباً عندما يضمن بقاء رؤية النظام واستبعاد البيانات السيئة [9-7]. لاحقاً في عام 2007 قام فريق من الباحثين بتطوير طريقة جديدة لمعالجة البيانات السيئة، تعتمد على التحليل الإحصائي لرواسب القياس [10] عرفت بنظرية الثغرة الإحصائية Gap Statistic Method حيث يتم حساب مربعات الفرق بين قيم القياسات الواردة والقيم المقيمة المحسوبة ففي حال كانت القياسات جيدة ستكون مربعات الفرق صغيرة جداً ومتقاربة، أي تقبل التجميع ضمن فئة إحصائية واحدة، أما في حال وجود البيانات السيئة ستكون بعض قيم مربعات الفرق كبيرة وبالتالي متباعدة ومشتتة إحصائياً ولن تقبل التجميع ضمن فئة إحصائية واحدة.

ومع التطور التكنولوجي الذي شهده مجال الاتصالات الفضائية تم استخدام تقنية القياسات الطورية في نظم القدرة الكهربائية، فظهرت عدة دراسات حديثة اعتمدت على هذه القياسات في تسهيل عملية تحديد البيانات السيئة منها تقييم الحالة ثنائي المراحل باستخدام القياسات الطورية [11] وتتمحور الفكرة الأساسية لهذه الطريقة حول تحويل مسألة تقييم الحالة من مسألة لا خطية تتطلب حلاً تكرارياً إلى مسألة خطية بسيطة وذلك من خلال إضافة القياسات الطورية إلى ناتج تقييم الحالة ومن ثم إعادة إجراء تقييم الحالة الخطي.

على الرغم من تنوع النظريات المستخدمة في حل مسألة البيانات السيئة إلا أنها تتصف معظمها بمنهجية حسابية تكرارية تتطلب الحصول على قياسات فائضة من نظام القدرة المدروس لوصفه بجملة معادلات فوق محددة (عدد القياسات أكبر من عدد متحولات الحالة) الأمر الذي يفرض عبءاً حسابياً كبيراً وقيوداً كثيرة على تطبيق هذه النظريات واعتمادها للعمل في الزمن الحقيقي الذي يضمن التشغيل والتحكم الفعال بنظام القدرة.

في هذا البحث سيتم توصيف نظام القدرة بجملة معادلات لا خطية دون محددة وتطوير شبكة عصبونية اصطناعية كنموذج مختزل لمقيم الحالة قادر على اكتشاف وتحديد البيانات السيئة بالاعتماد على عدد أقل من القياسات اللازمة لمقيمت الحالة الأخرى. وتمثل القياسات اللازمة لهذا النموذج الاستطاعة الفعلية والردية المحقونة في عقد الحمولة فقط.

أهمية البحث وأهدافه:

يقدم هذا البحث أسلوباً مختلفاً لمعالجة البيانات السيئة عن الطرق التكرارية والإحصائية المطولة المستخدمة سابقاً. ويوفر نموذجاً مختزلاً لمقيم الحالة يسمح بمراقبة نظام القدرة وتشغيله بطريقة فعالية وموثوقة بمتطلبات وعبء حسابي أقل وتنفيذ هذا الإجراء في الزمن الحقيقي وذلك ينعكس إيجاباً على عمل نظام إدارة الطاقة بالمجمل. ويهدف بشكل أساسي إلى تحسين عمل وظائف نظام إدارة القدرة الكهربائية باعتماد الشبكات العصبونية الاصطناعية.

طرائق البحث ومواده:

1- تقييم الحالة بالطريقة التقليدية والنموذج المختزل لمقيم الحالة المقترح:

عادة ما يتم إجراء تقييم الحالة قبل عملية اكتشاف وتحديد البيانات السيئة واستبعادها، حيث يعتمد مقيم الحالة التقليدي على مجموعة من القياسات الفائضة لوصف النظام بجملة معادلات لا خطية فوق محددة ومن ثم إجراء سلسلة من العمليات الرياضية العددية التكرارية تهدف لتصغير أخطاء القياس حتى الوصول إلى القيمة المثلى لمتحولات حالة النظام، وتعتبر نظرية مربعات الفرق الأصغرية الموزونة من أشهر الطرق المستخدمة لأجل ذلك. يتم التعبير عن كل قياس وارد بالنموذج التالي:

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

حيث أن:

z : شعاع القياسات، $h(x)$: شعاع التوابع اللاخطية التي تربط القياسات بمتحولات الحالة، e : شعاع أخطاء القياسات العشوائية.

بشكل عام تتضمن القياسات المأخوذة من النظام البيانات التالية:

$$z = [P_{inj}, P_{flow}, Q_{inj}, Q_{flow}, I_{mag}, V_{mag}]^T = v(x)$$

P_{inj} : الاستطاعة الفعلية المحقونة في العقدة، P_{flow} : الاستطاعة الفلية السارية بين عقدتين، Q_{inj} : الاستطاعة الردية المحقونة في العقدة، Q_{flow} : الاستطاعة الردية السارية بين عقدتين، I_{mag} : مطال التيار الساري بين عقدتين، V_{mag} : مطال توتر العقدة.

$x = [V_1, V_2, \dots, V_N, \theta_2, \theta_3, \dots, \theta_N]^T$, $N = \text{Total number of buses (assume bus 1 is the slack bus)}$

تهدف طريقة مربعات الفرق الأصغرية الموزونة إلى تصغير تابع الهدف التالي:

$$J(x) = f(z - h(x)) = (z - h(x))^T W (z - h(x)) \quad (2)$$

تكون شروط الامثلة محققة عندما يبلغ التابع السابق قيمته الصغرى:

$$g(x) = \frac{\partial J(x)}{\partial x} = -[H]^T [R]^{-1} [z - h(x)] = 0 \quad \text{where } [H(x)] = \left[\frac{\partial h(x)}{\partial x} \right]$$

بنشر التابع اللاخطي $g(x)$ وفق منشور تايلور حول شعاع الحالة x^k :

$$g(x) = g(x^k) + G(x^k)(x - x^k) + \dots = 0$$

وبإهمال الحدود ذات المراتب العليا نحصل على طريقة الحل التكرارية المعروفة نيوتن رافسون:

$$x^{k+1} = x^k - [G(x^k)]^{-1} \cdot g(x^k) \quad (3)$$

حيث أن :

k :رمز التكرار (iteration index) . x^k : شعاع الحل عند التكرار k .

$$G(x^k) = \frac{\partial g(x^k)}{\partial x} = [H(x^k)]^T [R]^{-1} [H(x^k)] , \quad g(x^k) = -[H(x^k)]^T [R]^{-1} [z - h(x^k)] .$$

$$[G(x^k)] \Delta x^{k+1} = [H(x^k)]^T [R]^{-1} [z - h(x^k)] \quad (4)$$

تُسمى المصفوفة $G(x)$ بمصفوفة الربح وهي مصفوفة مبعثرة وتكون موجبة ومتناظرة عندما يكون النظام بالكامل قابل للرؤية. إن النموذج المختزل المقترح في هذا البحث والذي يعتمد على الشبكات العصبونية الاصطناعية يحتاج فقط لقياسات قليلة ومحددة تتمثل بالاستطاعة الفعلية والرديئة المحقونة في عقد الحمولة وبالتالي يتحول النموذج الرياضي الذي يصف إلى الصيغة التالية:

$$\begin{bmatrix} P_L \\ Q_L \end{bmatrix} = f(x) \quad (5)$$

$$P_L = [P_{L1}, P_{L2}, \dots, P_{LM}]^T, \quad Q_L = [Q_{L1}, Q_{L2}, \dots, Q_{LM}]^T, \quad x = [V_1, V_2, \dots, V_N, \theta_2, \theta_3, \dots, \theta_N]^T$$

حيث أن:

M - عدد عقد الحمولة في النظام . N - العدد الكلي لعقد النظام .

$f(x)$ - مصفوفة التوابع اللاخطية التي تصف العلاقة بين متحولات الحالة وقياسات استطاعة الأحمال، و تمثل جملة معادلات دون محددة، ($M < N$) لوصف النظام.

من المعادلات (5) يمكن صياغة مصفوفة متحولات الحالة بالشكل التالي:

$$x = [V_1, V_2, \dots, V_N, \theta_2, \theta_3, \dots, \theta_N]^T = f^{-1}(P_L, Q_L) \quad (6)$$

حيث أن: f^{-1} تابع لا خطي يربط قياس استطاعة الحمل بمتحولات الحالة.

بتطبيق نموذج تقييم الحالة التقليدي الموصوف أعلاه يصبح لدينا مصفوفة القياسات Z ومصفوفة التوابع التي تربط القياسات بمتحولات الحالة $h(x)$ على الشكل التالي:

$$Z = \begin{bmatrix} P_L \\ Q_L \end{bmatrix} \quad (7)$$

$$h(x) = f(x) \quad (8)$$

$$Z = h(x) + e \leftrightarrow \begin{bmatrix} P_L \\ Q_L \end{bmatrix} = f(V, \theta) + e \quad (9)$$

وتصبح مصفوفة جاكوبيان القياسات $J(x)$ كالآتي:

$$J(x) = \frac{\partial f(x)}{\partial x} = \begin{bmatrix} \frac{\partial P_L}{\partial V} & \frac{\partial P_L}{\partial \theta} \\ \frac{\partial Q_L}{\partial V} & \frac{\partial Q_L}{\partial \theta} \end{bmatrix} \quad (10)$$

من الملاحظ أنه عند اختصار مجموعة القياسات المأخوذة من النظام فقط إلى قياسات عقد الحمولة أصبحت مصفوفة الجاكوبيان دون محددة.

2- اكتشاف وتحديد البيانات السيئة:

تفشل مقيمات الحالة التقليدية في تحديد البيانات السيئة الموجودة ضمن القياسات في حال كانت إحدى هذه البيانات تمثل قياساً حرجاً أو تنتمي إلى زوج من القياسات الحرجة أو مجموعة منها [9]. حيث يوصف أي قياس بأنه قياساً حرجاً عندما يصبح النظام المدروس غير قابل للرؤية بمجرد حذفه واستبعاده.

2-1 اكتشاف وتحديد البيانات السيئة المفردة:

من أشهر الطرق المستخدمة في اكتشاف وجود البيانات السيئة ضمن القياسات هي نظرية (Chi-squares²) مزيد من التفاصيل في المرجع [10]. وكذلك استخدمت نظرية رواسب القياس لكل من اكتشاف وتحديد البيانات السيئة ويمكن توضيح الفكرة العامة كالآتي:

$$r_i^N = \frac{|r_i|}{\sqrt{\Omega_{ii}}} \quad (11)$$

r_i راسب القياس i و Ω_{ii} العنصر المرتبط مع القياس i في مصفوفة تباين الرواسب.

يتم فحص القيمة الأكبر لرواسب القياسات ومقارنتها مع عتبة محددة إحصائياً لاكتشاف وجود البيانات السيئة ضمن مجموعة القياسات، وفي حال وجودها يكون القياس المشبوه بأنه يمثل بيانات سيئة هو القياس المرتبط بهذا الراسب. إن السبب الأساسي لاستخدام النموذج المختزل لمقيم الحالة الذي يعتمد الشبكات العصبونية في هذه المهمة بدلاً من الطرق التقليدية السابقة هو عدم الحاجة لمصفوفة تباين رواسب القياس والتي يمكن أن تكون عناصرها القطرية ذات القيمة القريبة من الصفر سبباً في فشل أو عدم دقة إجراء تحديد البيانات السيئة وكذلك فشل الطرق التقليدية عند وجود القياسات الحرجة.


2-2 اكتشاف وتحديد البيانات السيئة المتعددة:

تعتبر نظرية اختبار الفرض من أهم النظريات التقليدية المستخدمة لتحديد البيانات السيئة المتعددة ولكنها صعبة التطبيق من الناحية العملية، وكذلك بعض النظريات التي اعتمدت على الشبكات العصبونية الاصطناعية التي تقارن بين مربع فرق قيمة القياس والقيمة المخزنة له مع عتبة محددة مسبقاً مرتبطة بهذا القياس والتي تكون أكبر من الانحراف المعياري للقياس وأقل من قيمة خطأ حرج مستخدم لتحديد البيانات السيئة، ويمثل تحديد هذه العتبة تحدياً كبيراً أمام تطبيق هذه الطريقة على نظم مختلفة.

3- استخدام الشبكات العصبونية الاصطناعية لتحديد البيانات السيئة:

يقدم هذا البحث نموذجاً مختزلاً مكون من شبكة عصبونية اصطناعية متعددة الطبقات، الشكل (1) قادرة على تقييم حالة نظام القدرة واكتشاف وتحديد البيانات السيئة، ويعود سبب استخدام هذا النوع من الشبكات إلى قدرتها على تمثيل العلاقات اللاخطية التي تربط متحولات نظام القدرة الكهربائي مع القياسات المعتمدة، وقد تم تدريب هذه الشبكة

باستخدام خوارزمية الانتشار العكسي (BP) back-propagation وخوارزمية ليفنبرغ - ماركواديت Levenberg-Marquadt [12].




الشكل (1) شبكة عصبونية متعددة الطبقات

تتكون الشبكة المطورة من طبقة دخل وطبقتين مخفيتين وطبقة خرج، حيث تحتوي طبقة الدخل على 16 عصبون تمثل عدد القياسات ($N_m=16$) المأخوذة من نظام القدرة والمكونة فقط من الاستطاعة الفعلية والردية (P_L, Q_L) لعقد الأحمال في الشبكة ($B_{12} B_{11} B_{10} B_9 B_5 B_4 B_{13} B_{14}$) وتحتوي طبقة الخرج على 43 عصبون تمثل عدد متحولات الحالة ($N_n=27$) لنظام القدرة المدروس IEEE 14-bus power system الموضح بالشكل (2) بالإضافة إلى عدد القياسات المستخدمة على المداخل، وتحتوي الطبقة المخفية الأولى على 10 عصبونات والثانية على 8 عصبونات.

تم تشكيل النماذج التدريبية المكونة من 100 نموذجاً باستخدام PET Load Flow وقسمت إلى 70 نموذجاً للتدريب و 30 نموذجاً للاختبار، حيث يتكون كل نموذج من 16 عينة دخل و 43 عينة خرج، وتمثل عينات الدخل قياسات الاستطاعة الفعلية والردية في عقد الحمولة فقط وعينات الخرج قيم مطالات وزوايا جهود عقد النظام. تم اعتماد مجال تغير عينات الدخل ما بين $\pm 60\%$ من القيمة الأساسية لحمولة النظام النموذجي المدروس وذلك ضمن مجال التشغيل المستقر لنظام القدرة.

تم قياس أداء الشبكة العصبونية المطورة باستخدام معيار متوسط الخطأ التربيعي (Mean Square Error (MSE) لنتائج التدريب والاختبار، وكانت النتيجة كالتالي: متوسط الخطأ لبيانات التدريب 9.48×10^{-4} ومتوسط الخطأ لبيانات الاختبار 1.6×10^{-3} .



الشكل (2) نظام القدرة النموذجي المدروس IEEE 14-bus power system

3-1- تحديد البيانات السيئة المفردة:

لمقارنة أداء النموذج المختزل المطور في هذا البحث مع مقيم الحالة التقليدي WLS في اكتشاف وتحديد البيانات السيئة المفردة تم اختبار كل من النموذجين بإدخال بيانات سيئة مفردة على كل من القياسات التالية: P_4, P_9, Q_4, Q_9 بشكل عشوائي. وبوضوح يمكن ملاحظة أن الشبكة العصبونية المقترحة تمكنت من اكتشاف وتحديد البيانات السيئة المفردة ذات راسب القياس الأكبر في كل مرة بشكل دقيق وموثوق كما هو واضح في الجدول (1) حيث تمت الإشارة للبيانات السيئة برمز (*).

بينما لم يستطع مقيم الحالة التقليدي WLS تحقيق ذلك، حيث بالرجوع إلى الجدول (2) يمكن ملاحظة أن القياس المفرد السيء هو P_4 المقابل للراسب الأكبر لكن المقيم التقليدي حدد القياس P_{11} على أنه القياس المفرد السيء. وكذلك الأمر بالنسبة للقياس Q_2 الذي تم تحديده على أنه سيء بينما في الحقيقة القياس المفرد السيء هو Q_9 الموافق للراسب الأكبر.

تم تشغيل النموذج المقترح في هذا البحث ANN-BDDI MODEL والنموذج التقليدي WLS على نفس الجهاز الحاسوبي وكانت الأزمنة اللازمة لإتمام العملية كالتالي:

$$\text{CPU-TIME}_{\text{ANN}} = 0.04 \text{ sec and CPU-TIME}_{\text{WLS}} = 0.187 \text{ sec}$$

تظهر هذه النتائج دقة وسرعة النموذج المقترح وتفوقه على النموذج التقليدي مما يؤهله ليكون أداة فعالة لتحسين نظام إدارة الطاقة والعمل بموثوقية مع الشبكات الذكية.

3-2- تحديد البيانات السيئة المتعددة:

من أجل اختبار قدرة النموذج المقترح على تحديد البيانات السيئة المتعددة تم تحويل مجموعة من القياسات إلى بيانات سيئة من خلال إضافة خطأ يعادل 60 ضعفاً من الانحراف المعياري لكل قياس منها، تم اختيار ثلاث مجموعات من البيانات المتعددة لاختبار النموذج وهي كالتالي:

$$\text{Group}_1 = \{P_4, P_5\}, \text{Group}_2 = \{Q_4, Q_5, Q_{10}\}, \text{Group}_3 = \{P_{10}, Q_{12}, P_{14}, Q_{13}\}$$

توضح النتائج المعروضة في الجدول (3) أنه تم تحديد جميع البيانات السيئة لأجل كل مجموعة وبدقة عالية وبزمن قدره 0.07 ثانية.

الجدول (1) نتائج تحديد البيانات السيئة المفردة باستخدام النموذج المقترح:

رواسب القياس Residuals		البيانات السيئة المفردة Single Bad data			
		$P4=2.5$	$P9=1.6$	$Q4=1.2$	$Q9=1.3$
القياسات Measurement	$P4$	1.8605 *	0.2770	0.0325	0.6114
	$Q4$	0.0085	0.0123	2.7841*	0.0388
	$P5$	0.0253	0.0474	0.3102	0.1148
	$Q5$	0.0074	0.0085	0.0234	0.0029
	$P9$	0.0283	2.5739 *	0.0492	0.1614
	$Q9$	0.1011	0.1018	0.4670	2.2758*
	$P10$	0.6871	0.7217	0.2817	0.6196
	$Q10$	0.2252	0.2871	0.1988	0.6360
	$P11$	0.0082	0.0350	0.0366	0.0215
	$Q11$	0.0000	0.0000	0.0000	0.0004
	$P12$	0.0072	0.0025	0.9256	0.0119
	$Q12$	0.0041	0.0042	0.0223	0.00592
	$P13$	0.0012	0.0017	0.0906	0.0179
	$Q13$	0.0037	0.0038	0.0258	0.0042
	$P14$	0.0082	0.0071	0.0576	0.8877
	$Q14$	0.0039	0.0039	0.0151	0.0034

الجدول (2): نتائج تحديد البيانات السيئة المفردة باستخدام WLS:

رواسب القياس Residuals		البيانات السيئة المفردة Single Bad data			
		$P4=2.5$	$P9=1.6$	$Q4=1.2$	$Q9=1.3$
القياسات Measurement	$P2$	0.0029	0.0003	0.0236	0.0031
	$P3$	0.0031	0.0057	0.0901	0.0010
	$P4$	1.8087	0.0189	0.0005	0.0001
	$P9$	0.0090	2.188*	0.0001	0.0001
	$P10$	0.0673	0.1232	0.0069	0.0002

<i>P11</i>	0.2026*	0.4377	0.0017	0.0006
<i>P12</i>	0.0002	0.0000	0.1037	0.0000
<i>P14</i>	0.0005	0.0002	0.0127	0.3452
<i>Q2</i>	0.0005	0.0326	0.0107	0.0132*
<i>Q3</i>	0.0066	0.0331	0.0154	0.0087
<i>Q4</i>	0.0012	0.0184	1.919*	0.0049
<i>Q9</i>	0.0010	0.0173	0.0018	1.6210
<i>Q10</i>	0.0233	0.1346	0.0002	0.0002
<i>Q11</i>	0.0820	0.5110	0.0006	0.0005
<i>Q12</i>	0.0001	0.0000	0.4046	0.0001
<i>Q14</i>	0.0001	0.0000	0.0000	0.0005

الجدول (3): نتائج تحديد البيانات السيئة المتعددة باستخدام النموذج المقترح

رواسب القياس Residuals		Bad Data Group No. رقم مجموعة البيانات السيئة		
		1 {P ₄ , Q ₉ }	2 {Q ₄ , Q ₅ , Q ₁₀ }	3 {P ₁₀ , Q ₁₂ , P ₁₄ , Q ₁₃ }
القياسات Measurement	<i>P4</i>	10.4849*	-1.3947	-2.1245
	<i>Q4</i>	-1.2385	13.3644*	-1.3834
	<i>P5</i>	-1.6821	-1.2302	-3.9271
	<i>Q5</i>	-0.797	24.8044*	-0.8007
	<i>P9</i>	-0.4217	-0.2452	0.1412
	<i>Q9</i>	7.3155*	-1.1195	-1.8193
	<i>P10</i>	-4.690	-4.4081	11.4969*
	<i>Q10</i>	-0.8039	5.0182*	-0.1268
	<i>P11</i>	-0.448	-0.4497	-0.4515
	<i>Q11</i>	-1.3859	-1.3859	-1.3859
	<i>P12</i>	-4.6944	-4.6874	-5.7014
	<i>Q12</i>	-0.7955	-0.8031	14.8043*
	<i>P13</i>	-0.4427	-0.4364	-0.4501
	<i>Q13</i>	-1.3844	-1.3840	0.4537*
	<i>P14</i>	-4.6976	-4.6874	4.6996*
	<i>Q14</i>	-0.8044	-0.804	-0.8044

الاستنتاجات والتوصيات:

أظهرت هذه الدراسة قدرة النموذج المقترح على اكتشاف وتحديد البيانات السيئة المفردة والمتعددة بشكل دقيق وكذلك تفوق هذا النموذج على مقيم الحالة التقليدي WLS من حيث الدقة والزمن اللازم لإنجاز المهمة وهذا ما يؤهله ليكون أداة فعالة لتحسين أداء نظام إدارة الطاقة وزيادة موثوقيته.

نوصي بتطبيق الطريقة المقترحة في هذا البحث واختبار أدائها لأجل نظم قدرة كهربائية أكبر حجماً كنظام-IEEE118 bus power system وكذلك التوسع بالدراسة لتشمل تحديد البيانات السيئة المتعددة المرتبطة غير المتلائمة والمرتبطة المتلائمة.

Reference:

1. Mili L, Van Cutsem Th, Ribbens M. Bad data identification methods in power system state estimation – a comparative study. IEEE Power Engineering Review.1985 Nov; pp.30-37.
2. Handschin E, Schweppe FC, Kohlas J, Fiechter A. Bad data analysis for power system state estimation. IEEE Transactions on Power Apparatus and Systems.1975 Apr;94(2):329-339.
3. Alamin A, Khalid H, Peng J. Power system state estimation based on iterative extended Kalman filtering and bad data detection using normalized residual test. In:2015 IEEE Power and Energy Conference; pp.1-5.
4. Mili L, Van Cutsem Th, Ribbens M. Hypothesis testing identification: a new method for bad data analysis in power system state estimation. IEEE Power Engineering Review.1984 Nov; pp.32-39.
5. Mili L, Van Cutsem Th. Implementation of the hypothesis testing identification in power system state estimation. IEEE Transactions on Power System.1988 Aug;3:887-893.
6. Abur A, Gomez-Exposito A. Power system state estimation: theory and implementation. New York: Marcel Dekker;2004.
7. Garcia A, Monticelli A, Abreu P. Fast decoupled state estimation and bad data processing. IEEE Transactions on Power Apparatus and Systems.1975 Sep;98(5):1645-1652.
8. Monticelli A, Wu F, Yen M. Multiple bad data identification for state estimation by combinatorial optimization. IEEE Transactions on Power System.1986 Jul; PWRD-1(3).
9. Asada E, Garcia A, Romero R. Identifying multiple interacting bad data in power system state estimation. In:2005 IEEE Power Engineering Society Meeting; pp.571-577.
10. Lin JM, Pan HY. A static state estimation approach including bad data detection and identification in power systems. IEEE Transactions on Power Apparatus and Systems.2007 Sep;55(3):1645-1652.
11. Abur A, Tarali A. Bad data detection in two-stage state estimation using phasor measurements. IEEE Transactions on Power Apparatus and Systems.2012 Aug;31(2):548-554.
12. Lv C, Xing Y, Zhang J, Na X, Li Y, Liu T, Cao D, Wang FY. Levenberg-Marquardt backpropagation training of multilayer neural networks for state estimation of a safety critical cyber-physical system. IEEE Transactions on Industrial.2020;14(8).

