



التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية باستخدام تقنيات الذكاء الاصطناعي الضبابي

إعداد

د. محمد مسعد المعداوي

د. جيهان مسعد المعداوي

مدرس بقسم الإحصاء والتأمين
كلية التجارة، جامعة الزقازيق

أستاذ مساعد بقسم الإحصاء التطبيقي والتأمين
كلية التجارة، جامعة المنصورة

melmadawye@zu.edu.eg

gehanelmadawy@mans.edu.eg

د. نها عبد اللطيف عبد الحميد شاهين

أستاذ مساعد بقسم الإحصاء والرياضة والتأمين
كلية التجارة، جامعة كفر الشيخ

shahinnoha8787@yahoo.com

المجلة العلمية للدراسات والبحوث المالية والتجارية

كلية التجارة – جامعة دمياط

المجلد السابع – العدد الأول – الجزء الرابع – يناير 2026

التوثيق المقترح وفقاً لنظام APA:

المعداوي، جيهان مسعد؛ المعداوي، محمد مسعد؛ شاهين، نها عبد اللطيف عبد الحميد (2026). التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية باستخدام تقنيات الذكاء الاصطناعي الضبابي، *المجلة العلمية للدراسات والبحوث المالية والتجارية*، كلية التجارة، جامعة دمياط، 4(1)7، 613-589.

رابط المجلة: <https://cfdj.journals.ekb.eg/>

التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية باستخدام تقنيات الذكاء الاصطناعي الضبابي

د.جيهان مسعد المعداوي؛ د. محمد مسعد المعداوي؛ د. نها عبد اللطيف عبد الحميد شاهين

ملخص البحث:

يهدف هذا البحث إلى التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية من خلال تطبيق ومقارنة أداء ثلاثة نماذج تنبؤية لتقدير مخصص التعويضات السنوية بناءً على بيانات تاريخية للفترة من 2006 إلى 2023. حيث تم تطبيق النماذج الثلاثة: نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS)، ونموذج الانحدار الضبابي الهجين الثابت (Static HFLSR)، ونموذج الانحدار الضبابي الديناميكي (Dynamic HFLSR)، وأظهرت النتائج أن النموذج الديناميكي (Dynamic HFLSR) حقق أفضل أداء من حيث الدقة الإحصائية، حيث بلغ Fuzzy $MAPE = 9.49\%$ ، $MAE = 684105.4$ ، $RMSE = 868364.2$ ، $R^2 = 0.8874$ بينما قدم نموذج ANFIS أداءً جيداً في التعامل مع الأنماط غير الخطية، إلا أن دقته كانت أقل من النموذج الديناميكي. أما نموذج الانحدار الضبابي الهجين الثابت (Static HFLSR)، فقد أظهر أداءً متوسطاً. وتوصى الدراسة بتطبيق نموذج الانحدار الضبابي الديناميكي (Dynamic HFLSR) للتنبؤ بقيمة مخصص التعويضات، وذلك لما أظهره من تفوق في مستوى الدقة والأداء الإحصائي، وبالتالي يحسن من طريقة إدارة مخاطر الصناديق الحكومية ومن ثم تقليل الخطأ في تقدير قيمة المخصص. كما توصى الدراسة بإمكانية تعميم تطبيق هذا النموذج على مشاكل تنبؤ أخرى في المجال المالي والتأميني.

الكلمات المفتاحية: مخصص التعويضات – مجمع الصناديق الحكومية - نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS) - نموذج الانحدار الضبابي الهجين (HFLSR).

مقدمة:

يختلف تأمين الصناديق الحكومية عن جميع قطاعات التأمين الأخرى سواء الخاص أو قطاع الأعمال، حيث يقوم قطاع التأمين الحكومي بدوراً هاماً في تأمين الثروات وحمايتها ضد المخاطر التي تتعرض لها، بهدف تغطية الأخطار التي لا تقبلها عادة شركات التأمين أو تلك التي ترى الحكومة مزاولتها بنفسها (شاهين، 2020)، ولقد بلغ عدد صناديق التأمين الحكومية 6 صناديق (موقع الهيئة العامة للرقابة المالية، <https://fra.gov.eg>)، وهي:

- صندوق التأمين الحكومي لضمان أرباب العهد المنشأ بقرار مجلس الوزراء الصادر في 8 فبراير عام 1950.
- صندوق التأمين الحكومي لضمان الأخطار التي تتعرض لها الخدمات البريدية بموجب القرار رقم (98) لسنة 2003.
- صندوق التأمين التعاوني على مراكب الصيد للجمعيات التعاونية للثروة المائية وأعضائها بموجب قرار رقم (132) لسنة 2003.
- صندوق التأمين الحكومي لتغطية الأضرار الناتجة عن حوادث النقل السريع بموجب القانون رقم (72) لسنة 2007.
- صندوق التأمين الحكومي لرعاية طلاب مدارس مصر بموجب القرار رقم (1583) لسنة 2019.

- صندوق التأمين الحكومي على طلاب التعليم الأزهري بموجب القرار رقم (1584) لسنة 2019.

ولقد بلغ إجمالي أصول الصناديق 1.5 مليار جنيه، واستثمارات الصناديق 1.27 مليار جنيه لنفس العام، في حين بلغ إجمالي التعويضات المسددة خلال الفترة 143.6 مليون جنيه (الكتاب الإحصائي السنوي 2023/2022) وهو ما يوضح أهمية التنبؤ الدقيق بمخصص التعويضات تحت التسوية للنشاط التأميني، حيث قد يؤدي سوء تقدير هذه المخصصات إلى وجود عدة مشاكل تؤثر بصورة مباشرة أو غير مباشرة على قطاع التأمين والدولة ككل (هاشم، 1994)، وحيث أن المادة 13 (قرار مجلس الوزراء، 2019) عرفت مخصص التعويضات تحت التسوية بأنه المبلغ الذي تخصصه شركات التأمين وإعادة التأمين في نهاية الفترة المحاسبية لمواجهة التزاماتها تجاه حوادث وقعت وتم الإخطار عنها قبل نهاية تلك الفترة ولا تزال تحت التسوية أو لم تسدد بعد، وعليه فإن التنبؤ السليم لمخصص التعويضات تحت التسوية يعد أهم الوسائل المستخدمة في شركة التأمين لمواجهة الالتزامات المستقبلية والمحافظة على سلامة مركزها المالي.

ورغم أهمية صناديق التأمين الحكومي في تغطية الأخطار الكبيرة ذات المخاطر المرتفعة إلا أن الدراسات السابقة لا تزال محدودة في تناول الأخطار المتعلقة بتلك الصناديق، أما مخصص التعويضات تحت التسوية تم تناوله من خلال العديد من الدراسات السابقة، ومن هذه الدراسات: دراسة (محمد وآخرون، 2023) حيث هدفت إلى التنبؤ بمخصص التعويضات تحت التسوية بفرع تأمين البترول باستخدام نموذج الشبكات العصبية الموام بالفازية، وتوصلت الدراسة إلى مدى دقة نموذج ANFIS في التنبؤ. واستعرضت دراسة (خليل وآخرون، 2020) استخدام نموذج الشبكات العصبية الموام بالفازية (ANFIS) Adaptive Neuro-Fuzzy Inference System للتنبؤ بمعدل الخسارة لفرع تأمين الطيران، وأسفر النموذج عن تقديرات عالية الدقة.

وتناولت دراسة (علي وآخرون، 2023)، تقدير مخصص التعويضات تحت التسوية باستخدام نموذج الانحدار الخطي المتعدد، ونموذج الانحدار الخطي البيزي (Bayesian Linear Regression)، وتوصلت الدراسة إلى أن تقديرات نموذج الانحدار الخطي البيزي أكثر كفاءة. وفي دراسة (عطا وآخرون، 2022) تم استخدام الانحدار الخطي الضبابي في التنبؤ بمخصص التعويضات تحت التسوية في شركات التأمين المصرية. وهدفت دراسة (درويش، 2021) إلى التنبؤ بفائض النشاط التأميني لإحدى شركات تأمينات الممتلكات والمسؤولية باستخدام نموذج الانحدار الذاتي المضرب، وتوصلت الدراسة إلى أن نتائج النماذج الفازية أدق من نتائج السلاسل الزمنية التقليدية في التنبؤ.

بينما تناولت دراسة (عبد الحميد، 2015) التنبؤ باستخدام نماذج السلاسل الزمنية الفازية ومقارنتها بنماذج بوكس وجنكيز، وتوصلت الدراسة إلى أن نتائج نماذج بوكس وجنكيز أقل دقة في التنبؤ من نتائج السلاسل الزمنية الفازية. واستخدمت دراسة (الخواجه، 2014) أسلوب الانحدار المتعدد وأسلوب السلاسل الزمنية للتنبؤ بمخصص التعويضات تحت التسوية بسوق التأمين السعودي، وتوصلت الدراسة إلى أن التنبؤ باستخدام السلاسل الزمنية أفضل من استخدام الانحدار المتعدد. وتناولت دراسة (المعداوي، 2020) تقدير مخصص التعويضات تحت التسوية وفقاً للنماذج الخطية المعممة (GLM)، وأوصت الدراسة بأهمية استخدام الطرق الإحصائية لتقدير مخصص التعويضات تحت التسوية بالإستعانة بالبرامج الإحصائية والإكتوارية المتقدمة والمتخصصة.

وأوضحت دراسة (Karaboga & Kaya, 2019) الأساليب الاستدلالية والهجينة المستخدمة في تدريب ANFIS بهدف توجيه الباحثين في أبحاثهم وتقييم الوضع الحالي لأساليب التدريب، وتقديم رؤية قد تساهم في تطوير الدراسات المستقبلية في هذا المجال. وفي دراسة (Giovanis, 2010)، تم استخدام نموذج (Logit, Probit) ونموذج الاستدلال العصبي الضبابي التكيفي (ANFIS) للتنبؤ بفترات الركود أو التوسع الاقتصادي في الولايات المتحدة الأمريكية، وأوضحت النتائج أن نموذج ANFIS يتفوق بشكل ملحوظ على نموذجي (Probit, Logit).

وتناولت دراسة (Tanaka & Asai, 1982) الانحدار الضبابي (Fuzzy Regression)، حيث قدمت أول نموذج للتعامل مع البيانات غير المؤكدة باستخدام المعاملات الضبابية. وقدمت دراسة (Chang, 2001) نموذج الانحدار الضبابي الهجين بالمربعات الصغرى (Hybrid Fuzzy Least Square Regression (HFLSR)، الذي يدمج بين منهج المربعات الصغرى الكلاسيكي والمنطق الضبابي، وأظهرت نتائج الدراسة أن النموذج الهجين يوفر ملائمة أفضل للبيانات مقارنة بالنماذج الاحتمالية التقليدية، مما يجعل نموذج (HFLSR) إضافة مهمة لتطوير نماذج الانحدار في ظل البيانات ذات عدم اليقين. واعتمدت دراسة (Apaydin & Baser, 2010) على نموذج الانحدار الضبابي الهجين بالمربعات الصغرى (HFLSR) الذي تم اقتراحه في دراسة (Chang, 2001)، لتقدير مخصص التعويضات في مجال التأمين مع مراعاة عدم اليقين في البيانات التأمينية. وهدفت دراسة (Woundjiague et al., 2019) إلى تطوير نموذج هجين يدمج بين انحدار بواسون اللوغاريتمي وطريقة المربعات الصغرى الضبابية (Fuzzy Least Squares)، لمعالجة حالة عدم اليقين والضبابية في البيانات لتقدير مخصص التعويضات في تأمين الإصابات الجسدية. وتوصلت الدراسة إلى أن النموذج الهجين قدم أداء أفضل من النموذج الكلاسيكي من حيث مؤشر الملائمة ومتوسط مربع خطأ التنبؤ.

وباستعراض الدراسات السابقة، وجد أنها تناولت التنبؤ بمخصص التعويضات تحت التسوية في شركات التأمين ولم تتطرق إلى التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية، ولذلك، في هذه الدراسة سوف يتم استخدام ثلاثة نماذج للتنبؤ بمخصص تعويضات مجمع الصناديق الحكومية.

وتتمثل مشكلة البحث في أن التنبؤ الدقيق بمخصص التعويضات أصبح من أبرز التحديات التي تواجه المؤسسات المالية وشركات التأمين، إذ يمثل عنصرًا أساسيًا في إدارة المخاطر المالية وضمان الإستدامة المالية للأعمال، ومع تزايد تعقيد البيانات المالية وما يصاحبها من غموض وعدم يقين، أصبح من الضروري الاعتماد على نماذج قادرة على التنبؤ بصورة أكثر فعالية للتعامل مع هذه التحديات. ونظرًا لإختلاف طبيعة التأمين في صناديق التأمين الحكومي عن باقي أنواع التأمين الأخرى، وذلك لطبيعة الأخطار المغطاة، حيث تتكفل الحكومة بتغطية الأخطار التي لا تقبلها شركات التأمين، نظرًا لارتفاع درجة خطورتها، بالإضافة إلى أن سعر التأمين يكون محددًا مقدماً بموجب القانون ولا يتغير حسب النتائج المحققة (مظهر، 1999)، لذلك كان من الأهمية التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية من خلال الاعتماد على خبرة التعويضات في الماضي، والأساليب والنماذج الإحصائية والرياضية الحديثة في التنبؤ. ونظرًا لأن استخدام المنطق الضبابي أصبح شائعًا في عدة مجالات، ومنها مجال التأمين، لأنه من التقنيات التي تتمتع بقدرات آلية كبيرة في إيجاد حلول دقيقة للعديد من القضايا، كما أسهمت نظرية الفئات الفازية في الحصول على أعلى مستويات الدقة في التحليل الإحصائي مقارنة بأساليب التحليل الإحصائي التقليدية (عباس، 2022). ولذلك في هذه الدراسة سوف نتناول استخدام نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS)، ونموذج الانحدار الضبابي الهجين (HFLSR) للتنبؤ بمخصص تعويضات مجمع الصناديق الحكومية.

ومما سبق يهدف هذا البحث إلى التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية باستخدام تقنيات الذكاء الاصطناعي المتمثلة في النماذج التالية:

- 1- نموذج الاستدلال العصبي الضبابي التكيفي: Adaptive Neuro-Fuzzy Inference System (ANFIS).
- 2- نموذج الانحدار الضبابي الهجين الثابت: Static Hybrid Fuzzy Least squares Regression (Static HFLSR).
- 3- نموذج الانحدار الضبابي الهجين الديناميكي: Dynamic Hybrid Fuzzy Least squares Regression (Dynamic HFLSR).

وأيضاً مقارنة أداء هذه النماذج لتحديد النموذج الأكثر دقة للتنبؤ بمخصص التعويضات المستقبلية لمجمع الصناديق الحكومية، مما يساهم في دعم عملية اتخاذ القرار ورفع كفاءة التخطيط المالي للصناديق الحكومية.

وترجع أهمية البحث إلى أهمية الدور الذي تقوم به صناديق التأمين الحكومي، حيث تعمل تلك الصناديق طبقاً للمادة 24 من القانون رقم 10 لسنة 1981 على تغطية الأخطار التي لا تقبلها شركات التأمين نتيجة لارتفاع درجة الخطر بها، وهو ما يدعو إلى ضرورة العمل على التنبؤ السليم بالمخاطر المحتملة ومخصص التعويضات تحت التسوية، حتى يمكن توجيه أكبر قدر من تلك الأموال للاستثمار وتحقيق عائد استثمار يساعد في تحقيق الهدف القومي الذي من أجله قامت الحكومة بتغطية تلك المخاطر.

أولاً: نماذج التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية:

سوف يتم التنبؤ بمخصص تعويضات مجمع الصناديق الحكومية من خلال نموذجين متطورين وهما: نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS) ونموذج الانحدار الضبابي الهجين (HFLSR). وفيما يلي عرض الإطار المنهجي لكل نموذج على النحو التالي:

1) النموذج الأول: نموذج الاستدلال العصبي الضبابي التكيفي

The Adaptive Neuro-Fuzzy Inference System (ANFIS)

نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS)، يعد أحد أساليب التنقيب في البيانات، وهو من الأنظمة الذكية الهجينة التي تجمع بين قدرة نظم المنطق الضبابي على تمثيل المعرفة اللغوية والاستدلال التقريبي، وقدرة الشبكات العصبية الاصطناعية على التعلم من البيانات والتكيف. قدم هذا النموذج العالم (Jang, 1993)، ويهدف ANFIS إلى تحقيق الدقة العالية للشبكات العصبية مع الحفاظ على القابلية للتفسير والشفافية التي توفرها نظم المنطق الضبابي، مما يجعله أداة فعالة في نمذجة الأنظمة المعقدة غير الخطية، مثل تلك السائدة في مجال التمويل والتأمين.

مكونات النموذج:

يتكون نموذج الشبكات العصبية الفازية (ANFIS) من خمس طبقات:

(Pakdel et al., 2025; Karaboga & Kaya, 2019; Fang, 2012; Giovanis, 2010)

لنفترض نظاماً بمدخلين x, y وقاعدتين ضبابيتين من نوع Sugeno من الدرجة الأولى:

Rule 1: IF x is A_1 and y is B_1 then $f_1 = p_1x + q_1y + r_1$

Rule 2: IF x is A_2 and y is B_2 then $f_2 = p_2x + q_2y + r_2$

حيث A_i, B_i مجموعات ضبابية، و p_i, q_i, r_i معاملات خطية.

الطبقة الأولى: طبقة التضبيب (Fuzzification Layer)

حيث يتم تحويل القيم العددية للمدخلات إلى درجات عضوية من خلال دوال العضوية كالتالي:

$$o_i^1 = \mu A_i(x) \quad , \quad i = 1, 2, \dots \quad (1)$$

حيث أن: $\mu A_i(x)$ تمثل درجة انتماء x إلى المجموعة الفازية A_i ، وتستخدم دالة العضوية جاوس (Gaussian Membership Function) التالية:

$$o_i^1 = \mu_{A_i}(x) = \exp\left(-\frac{(x - c_i)^2}{2\sigma_i^2}\right) \quad (2)$$

الطبقة الثانية: طبقة القواعد (Rule Layer)

تحتسب درجة تنشيط كل قاعدة ضبابية من خلال حاصل ضرب درجات العضوية.

$$o_i^2 = w_i = \mu A_i(x) \cdot \mu B_i(y) \quad , \quad i = 1, 2 \quad (3)$$

الطبقة الثالثة: طبقة التطبيع (Normalization Layer)، حيث تقوم بحساب قوى التنشيط المطبوعة (Normalized Firing Strengths) الخاصة بكل قاعدة (i)، القيمة المطبوعة هي النسبة بين قوة التنشيط للقاعدة رقم (i) إلى مجموع قوى التنشيط لجميع القواعد، كما هو موضح في المعادلة التالية:

$$o_i^3 = \bar{w}_i = \frac{w_i}{\sum_i w_i} \quad (4)$$

والهدف الرئيسي هو تطبيع القيم لضمان أن مجموع تأثيرات جميع القواعد يساوى 1، مما يسمح بتفسير المخرجات كنسب مئوية أو أوزان نسبية تظهر مساهمة كل قاعدة في الناتج النهائي.

الطبقة الرابعة: طبقة إزالة التضبيب (Defuzzification Layer)

يتم حساب القيم الموزنة للقواعد في كل عقدة من هذه الطبقة كما هو موضح في المعادلة التالية:

$$o_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad , \quad i = 1, 2 \quad (5)$$

حيث أن: \bar{w}_i ناتج طبقة التطبيع، $\{p_i, q_i, r_i\}$ هي مجموعة المعلمات الخاصة بهذه الطبقة، ويطلق عليها معلمات الـ (Consequence Parameters)، عدد معلمات التتابع لكل قاعدة يكون عبارة عن (عدد المدخلات + 1).

الطبقة الخامسة: طبقة الجمع (Summation Layer) يتم الحصول على المخرجات الفعلية لنموذج ANFIS من خلال جمع المخرجات الناتجة عن كل قاعدة في طبقة إزالة التضبيب

$$o_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (6)$$

يستخدم نموذج ANFIS خوارزمية تعلم هجين، حيث يقوم بتحديث معالم دوال العضوية باستخدام خوارزمية الانتشار العكسي (Backpropagation)، ويتم تقدير معاملات الطبقة الرابعة باستخدام الانحدار الخطي، مما يعزز دقة التنبؤ مع الحفاظ على قابلية تفسير النتائج.

2) النموذج الثاني: نموذج الانحدار الضبابي الهجين:

Hybrid Fuzzy Least-Squares Regression (HFLSR)

يعتبر نموذج الانحدار الضبابي الهجين (HFLSR)، تطوراً مهماً في نمذجة العلاقات الإحصائية في ظل ظروف عدم اليقين، حيث يمثل هذا النموذج اندماجاً بين تقنيات الانحدار الكلاسيكي ونظرية المجموعات الضبابية، وبالتالي يجمع بين دقة الأساليب الإحصائية وقوة النماذج الضبابية، مما يجعله أداة فعالة لمعالجة البيانات ذات الطبيعة الغامضة أو غير الدقيقة، وبالتالي زيادة دقة التنبؤ في حالة وجود غموض بالبيانات، وفيما يلي توضيح لهذا النموذج:

(Hyndman & Athanasopoulos, 2018; Chang, 2001; Ayyub & Gupta, 1997; Lawrence, 1993).

نموذج الانحدار الضبابي للمتغير المستقل \tilde{X}_i والمتغير التابع \tilde{Y}_i :

$$\tilde{Y}_i = \tilde{A}_0 + \tilde{A}_1 * \tilde{X}_i + \tilde{E}_i \quad (7)$$

حيث:

المتغير التابع الضبابي $\tilde{Y}_i = (y_{ia}, y_{ic}, y_{ib})$

المتغير المستقل الضبابي $\tilde{X}_i = (x_{ia}, x_{ic}, x_{ib})$

التقاطع الضبابي (الحد الثابت أو التقاطع مع المحور الصادي) $\tilde{A}_0 = (a_0, c_0, b_0)$

الميل الضبابي $\tilde{A}_1 = (a_1, c_1, b_1)$

الحد الضبابي للخطأ \tilde{E}_i

التنبؤ الضبابي لكل مكون:

$$\begin{aligned} \hat{y}_{ia} &= a_0 + a_1 x_{ia} \\ \hat{y}_{ic} &= c_0 + c_1 x_{ic} \\ \hat{y}_{ib} &= b_0 + b_1 x_{ib} \end{aligned} \quad (8)$$

دالة الهدف لتقدير المعاملات الضبابية هي تصغير مجموع المسافات التربيعية، (Jimenez, 2016)

$$S = \sum_{i=1}^n (y_{ia} - \hat{y}_{ia})^2 + (y_{ic} - \hat{y}_{ic})^2 + (y_{ib} - \hat{y}_{ib})^2 \quad (9)$$

المعادلات الرياضية للمكونات الضبابية:

المكون المركزي: (C)

$$\begin{aligned} nc_0 + c_1 \sum x_{ic} &= \sum y_{ic} \\ c_0 \sum x_{ic} + c_1 \sum x_{ic}^2 &= \sum y_{ic} x_{ic} \end{aligned} \quad (10)$$

المكون الأيسر: (a)

$$\begin{aligned} na_0 + a_1 \sum x_{ia} &= \sum y_{ia} \\ a_0 \sum x_{ia} + a_1 \sum x_{ia}^2 &= \sum y_{ia} x_{ia} \end{aligned} \quad (11)$$

المكون الأيمن: (b)

$$\begin{aligned} nb_0 + b_1 \sum x_{ib} &= \sum y_{ib} \\ b_0 \sum x_{ib} + b_1 \sum x_{ib}^2 &= \sum y_{ib} x_{ib} \end{aligned} \quad (12)$$

وبحل كل معادلتين معاً نحصل على معاملات الانحدار المجهولة، ومن ثمة يكون لدينا ثلاث معادلات للانحدار: معادلة الانحدار (المكون المركزي - المكون الأيسر - المكون الأيمن)، وبالتالي إيجاد التنبؤ الضبابي لكل سنة.

متوسط المسافة التربيعية (Mean Squared Diamond Distance (MSD)) ومعامل التحديد الضبابي R^2 :

حساب المسافة التربيعية لكل سنة:

$$D^2(\tilde{Y}_i, \hat{Y}_i) = D_i^2 = (L_i - \hat{L}_i)^2 + (C_i - \hat{C}_i)^2 + (U_i - \hat{U}_i)^2 \quad (13)$$

أو تكتب على الصورة التالية:

$$D^2(\tilde{Y}_i, \hat{Y}_i) = D_i^2 = \sum_{i=1}^n (y_{ia} - \hat{y}_{ia})^2 + (y_{ic} - \hat{y}_{ic})^2 + (y_{ib} - \hat{y}_{ib})^2 \quad (14)$$

ويمكن إيجاد (MSD)، كالتالي :

$$D_{\text{mean}}^2 = (MSD) = \frac{1}{n} \sum D^2(\tilde{Y}_i, \hat{Y}_i) \quad (15)$$

ويمكن إيجاد معامل التحديد الضبابي R^2 كالتالي:

$$R_{fuzzy}^2 = 1 - \frac{\sum D^2(\tilde{Y}_i, \hat{Y}_i)}{\sum D^2(\tilde{Y}_i, \tilde{Y})} = 1 - \frac{\sum D_i^2}{\sum D^2(\tilde{Y}_i, \tilde{Y})} \quad (16)$$

حيث أن:

$\sum D^2(\tilde{Y}_i, \hat{Y}_i)$: مجموع مربعات الفروق بين القيم الفعلية والقيم المتوقعة المتنبأ بها النموذج.

$\sum D^2(\tilde{Y}_i, \tilde{Y})$: مجموع مربعات الفروق بين القيم الفعلية ومتوسطها.

ثانياً: قياس كفاءة ودقة النماذج:

يتم قياس دقة التنبؤ وكفاءة النماذج من خلال المقاييس التالية:

- **المتوسط المطلق لأخطاء التقدير (MAE):** يقيس متوسط الفروق المطلقة بين القيم المتوقعة والفعلية.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (17)$$

- متوسط مربعات أخطاء التقدير (MSE): يحسب متوسط مربعات الفروق بين القيم المتوقعة والفعلية

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (18)$$

- الجذر التربيعي لمتوسط مربعات أخطاء التقدير (RMSE):

$$RMSE = \sqrt{MSE} \quad (19)$$

- المتوسط المطلق لنسبة أخطاء التقدير (MAPE):

يعبر عن الخطأ كنسبة مئوية من القيم الفعلية

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (20)$$

ثالثاً: بيانات الدراسة:

تم الاعتماد على بيانات مخصص تعويضات مجمع الصناديق الحكومية المستخرجة من الكتاب الإحصائي السنوي عن نشاط التأمين خلال الأعوام المالية (2006-2023)، وكانت على النحو الموضح في جدول (1).

جدول (1): يوضح مخصص تعويضات مجمع الصناديق الحكومية بالآلاف جنيه:

السنة	2006	2007	2008	2009	2010	2011	2012	2013	2014
مخصص التعويضات	2500	3288	3512	4881	5334	5290	6416	8156	—
السنة	2015	2016	2017	2018	2019	2020	2021	2022	2023
مخصص التعويضات	—	—	—	6417	10256	8850	10217	14976	5092

(-) البيانات غير متاحة. المصدر: الكتاب الإحصائي السنوي عن نشاط التأمين خلال الأعوام المالية (2006-2023).

وتم استخدام البرنامج الإحصائي R لإجراء الدراسة التطبيقية وبالاعتماد على الحزم التالية:

(dplyr, ggplot2, tibble, patchwork, scales and nnls).

(Wickham *et al.*, 2023; Wickham, 2016; Müller & Wickham, 2023; Pedersen, 2020; Wickham & Seidel, 2023; Mullen, 2023).

ومن جدول (1) اتضح عدم توفر البيانات الخاصة بالسنوات التالية (2014، 2015، 2016، 2017) مما دعت الحاجة إلى استخدام طريقة الاستكمال الخطي (Linear interpolation) لتقدير تلك القيم المفقودة، وذلك في ضوء القيود الواقعية التي واجهتها الدراسة على النحو التالي:

1- ندرة البيانات وعدم توافر المصادر البديلة، حيث تعد بيانات مخصص التعويضات الصناديق الحكومية من المصادر المغلقة ذات الطابع الإداري.

2- صغر حجم العينة وضرورة الحفاظ على البنية الزمنية للعينة، حيث أن العينة عبارة عن (18 مفردة 2006-2023)، وبالتالي فإن استبعاد 4 سنوات متتالية (2014-2017) بما يعادل 22% من إجمالي العينة سيؤدي إلى عدم تمثيل الاتجاه العام للبيانات، وكذلك تقليل القدرة الإحصائية للنماذج وبخاصة الديناميكية لاعتمادها على استمرارية التسلسل الزمني لتقدير الانتشار الضبابي.

3- تعد طريقة الاستكمال الخطي حلاً عملياً ومعتمد في الدراسات التطبيقية ذات العينات الصغيرة، بهدف الحفاظ على هيكل السلسلة الزمنية دون إدخال افتراضيات نموذجية معقدة مثل (Spline, ARIMA)، التي قد تزيد من احتمالات التحيز في النموذج. وقد استخدمت هذه الطريقة في دراسات سابقة في المجال التأميني والإحصائي في حالة ندرة البيانات (Kahya, 2005; Enders, 2010; Hyndman & Athanasopoulos, 2018; Little & Rubin, 2019).

وفيما يلي نتناول طريقة الاستكمال الخطي.

طريقة الاستكمال الخطي (Linear interpolation):

لتقدير القيم المجهولة بين نقطتي بيانات معروفتين بافتراض وجود علاقة خطية بينهما، وبافتراض معلومية النقطتين (x_0, y_0) ، (x_1, y_1) يتم إيجاد قيمة (y) بالنسبة لنقطة (x) حيث أن: $(x_0 < x < x_1)$ من المعادلة التالية (Kahya, 2005):

$$y_{(interpolated)} = y_0 + \frac{(y_1 - y_0)}{(x_1 - x_0)} * (x - x_0)$$

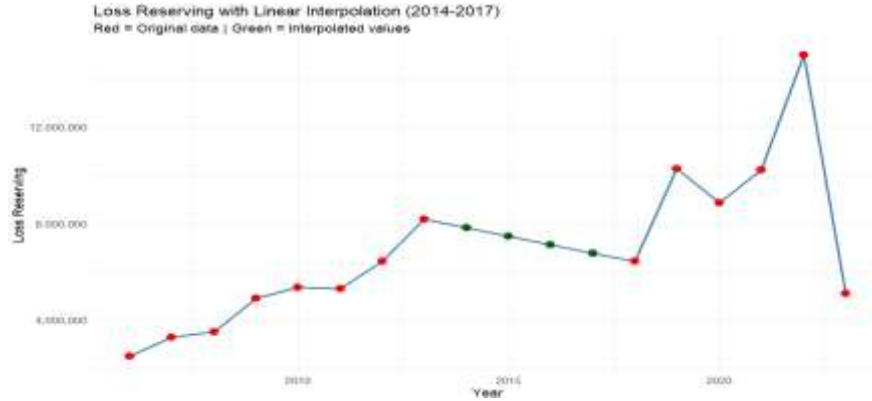
وبالتالي تم إيجاد القيم المفقودة حيث كانت كالتالي:

السنة	2014	2015	2016	2017
مخصص تعويضات مجمع الصناديق	7808200	7460400	7112600	6764800

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.

جدول(2): يوضح مخصص تعويضات مجمع الصناديق الحكومية بعد التنبؤ بالقيم المفقودة:

السنة	2006	2007	2008	2009	2010	2011
القيم الفعلية	2500000	3288000	3512000	4881000	5334000	5290000
السنة	2012	2013	2014	2015	2016	2017
القيم الفعلية	6416000	8156000	7808200	7460400	7112600	6764800
السنة	2018	2019	2020	2021	2022	2023
القيم الفعلية	6417000	10256000	8850000	10217000	14976000	5092000



شكل (1): يوضح مخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2006 إلى 2023.

ويوضح شكل (1) ارتفاع ملحوظ في قيمة مخصص تعويضات مجمع الصناديق الحكومية لعام 2022 مقارنة بالسنوات السابقة، حيث بلغت 14.9 مليون. وهو نمط يمكن تفسيره في ضوء الطبيعة الخاصة لمجمع الصناديق الحكومية، حيث تنسم الأخطار المغطاة بارتفاع الشدة (High severity) وانخفاض التكرار (Low Frequency). ويحتمل أن يعزى هذا الارتفاع لوقوع مطالبات كبيرة الحجم أو مجموعة من المطالبات المؤجلة وتم تسويتها خلال عام 2022، أو نتيجة تغيير في الإجراءات التنظيمية أو المحاسبية الخاصة بآلية الصرف داخل الصناديق. أو حدوث إعادة هيكلة أو دمج لصناديق فرعية مما أدى لزيادة مؤقتة في قيمة مخصص التعويضات المسجلة خلال هذا العام. وتعتبر تلك القفزة سمة مألوفة في البيانات التأمينية الحكومية، ولا تعتبر بالضرورة تغييراً هيكلياً في نمط المخاطر على المدى الطويل.

الإحصاءات الوصفية لبيانات مخصص تعويضات مجمع الصناديق الحكومية موضحة في جدول (3) على النحو التالي:

جدول (3) يوضح الإحصاءات الوصفية لمخصص تعويضات مجمع الصناديق الحكومية:

Descriptive Statistics	Sample Size	Minimum	Maximum	Mean	Standard deviation
	18	2500000	14976000	6925700	2898300

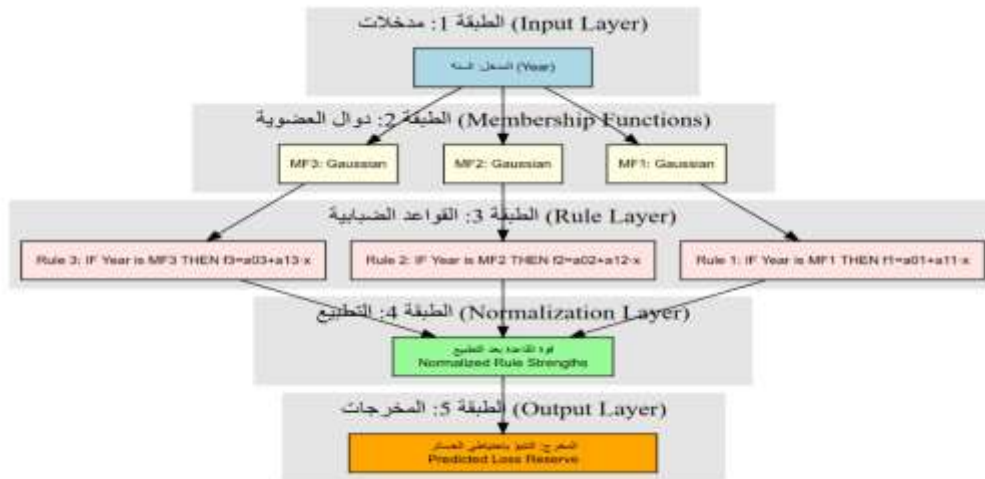
المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R

رابعاً: الدراسة التطبيقية:

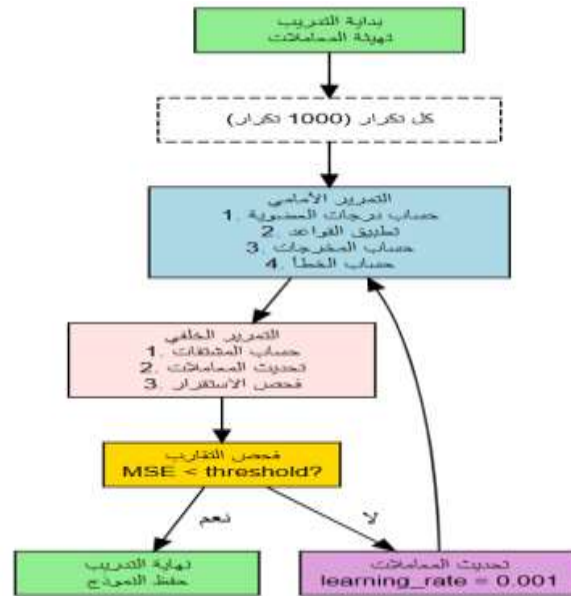
1- نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS):

تم تطوير نموذج ANFIS، باستخدام متغير الزمن (Year Index) كمدخل وحيد، حيث تم ترميز السنوات (2006-2023)، ليكون المدخل الوحيد للنموذج، وتم تصميم النموذج وفقاً للبنية التخطيطية التالية: عدد المدخلات 1 وتمثل المتغير الزمني، عدد المخرجات 1 وتمثل قيمة مخصص التعويضات، عدد المجموعات الضبابية 3 مجموعات من النوع (Gaussian)، عدد القواعد الضبابية 3 قواعد من النوع (Sugeno) من الدرجة الأولى تمثل ثلاث علاقات خطية بين المدخل والمخرج، تم استخدام خوارزمية تدريب هجينة تجمع بين طريقة الانتشار العكسي (Backpropagation)

لتحديث معالم دوال العضوية، وطريقة المربعات الصغرى لتقدير معاملات الطبقة الرابعة، معدل التعلم (0.001)، عدد التكرارات (Epochs: 1000) مع تحديث معالم الشبكة كل 1000 تكرار، ونظرًا لصغر حجم العينة (18 ملاحظة) تم استخدام جميع البيانات (2006 - 2023) في مرحلة التدريب دون تقسيم منفصل للإختبار أو التحقق حيث لوحظ تدهور كبير في أداء النموذج عند تقسيم البيانات إلى مجموعة تدريب ومجموعة إختبار. وتم توثيق الهيكل التخطيطي للنموذج (شكل 2) وخطوات تدريب النموذج (شكل 3).



شكل (2): يوضح الهيكل التخطيطي لنموذج ANFIS المستخدم للتنبؤ بقيمة مخصص تعويضات مجمع الصناديق الحكومية.



شكل (3): يوضح خطوات التدريب لنموذج ANFIS المستخدم للتنبؤ بقيمة مخصص تعويضات مجمع الصناديق الحكومية.

جدول (4): يوضح القيم الفعلية والقيم المتوقعة لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2006: 2023 وفقاً لنموذج ANFIS:

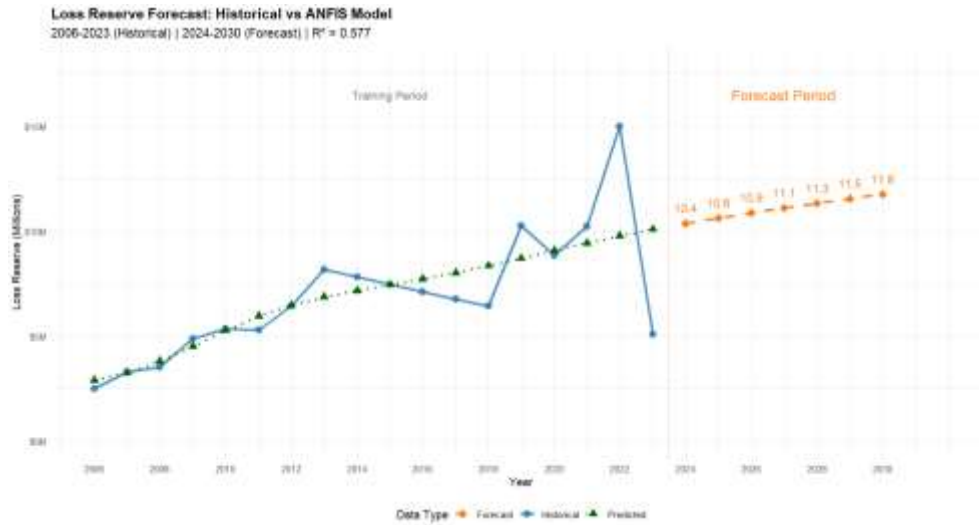
السنة	Actual (القيم الفعلية)	ANFIS Predicted	Error
2006	2500000	2881874	-381874
2007	3288000	3252822	35178
2008	3512000	3796433	-284433
2009	4881000	4498645	382355
2010	5334000	5259065	74935
2011	5290000	5938805	-648805
2012	6416000	6464250	-48250
2013	8156000	6853265	1302735
2014	7808200	7161129	647071
2015	7460400	7436976	23424
2016	7112600	7715764	-603164
2017	6764800	8016895	-1252095
2018	6417000	8346716	-1929716
2019	10256000	8699991	1556009
2020	8850000	9066589	-216589
2021	10217000	9424849	792151
2022	14976000	9763969	5212031
2023	5092000	10083366	-4991366

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.

جدول (5): يوضح القيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2024: 2030 وفقاً لنموذج ANFIS :

السنة	2024	2025	2026	2027	2028	2029	2030
ANFIS (future)	10358194	10619015	1086272	11094592	11318766	11538173	11754746

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.



شكل (4): يوضح القيم الفعلية والقيم المتوقعة والقيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية وفقاً لنموذج ANFIS:

يتضح من شكل (4) أن نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS)، له قدرة متوسطة على تمثيل بيانات مخصص تعويضات مجمع الصناديق الحكومية التاريخية، حيث بلغ معامل التحديد $R^2 = 0.577$ ، كما يظهر النموذج اتجاهاً تصاعدياً مستقرًا للقيم المستقبلية خلال الفترة (2024-2030)، وهو ما يعكس استجابته الجيدة للاتجاه العام للبيانات.

2- نموذج الانحدار الضبابي الهجين:

سيتم تطبيق نموذج الانحدار الضبابي الهجين باستخدام كل من النموذج الثابت (Static HFLSR) والنموذج الديناميكي (Dynamic HFLSR)، وذلك لتحقيق أفضل دقة في التنبؤ بالقيم المستقبلية لمخصص التعويضات على النحو التالي:

1-2- نموذج الانحدار الضبابي الهجين الثابت (Static HFLSR):

في نموذج الانحدار الضبابي الهجين الثابت (Static HFLSR) يفترض أن العلاقة بين \tilde{Y} ، ثابتة خلال الزمن، ويتم تطبيق هذا النموذج وفق الخطوات الآتية:

- تكويد المتغير المستقل (X) من (0 إلى 17).
- تحويل البيانات إلى أعداد ضبابية ثلاثية: حيث نفترض هامش ضبابي قدره ± 1000000 ،

$$\tilde{Y}_i = (L_i, C_i, U_i) = (Y_i - 1000000, Y_i, Y_i + 1000000)$$

- حساب معاملات الانحدار لكل مكون.
- معادلة الانحدار الضبابي للبيانات الأصلية (المركز (C))

$$\hat{y}_{ic} = 3392707.6 + 413478.8x_i$$

- معادلة الانحدار الحد الأدنى:

$$\hat{y}_{il} = 2392707.6 + 413478.8x_i$$

➤ معادلة الانحدار الحد الأعلى:

$$\hat{y}_{iu} = 4392707.6 + 413478.8x_i$$

وباستخدام المعادلات السابقة، تم إيجاد القيم الفعلية والقيم المتوقعة بحدودها (Lower, Center, Upper) لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2006 : 2023 وفقاً لنموذج (Static HFLSR) كما هو موضح في جدول (6).

وبعد إيجاد القيمة الفعلية والمتوقعة بحدودها (Lower, Center, Upper) في الفترة من (2006:2023)، يتم التنبؤ بالقيم المستقبلية في الفترة من (2024:2030) لمخصص تعويضات مجمع الصناديق الحكومية، وموضح ذلك في جدول (7).

جدول (6): يوضح القيم الفعلية والقيم المتوقعة بحدودها (Lower, Center, Upper) لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2006 : 2023 وفقاً لنموذج (Static HFLSR):


السنة (x)	Year Index	y_{iL}	y_{ic}	y_{iu}	\hat{y}_{iL}	\hat{y}_{ic}	\hat{y}_{iu}
2006	0	1500000	2500000	3500000	2392708	3392708	4392708
2007	1	2288000	3288000	4288000	2806186	3806186	4806186
2008	2	2512000	3512000	4512000	3219665	4219665	5219665
2009	3	3881000	4881000	5881000	3633144	4633144	5633144
2010	4	4334000	5334000	6334000	4046623	5046623	6046623
2011	5	4290000	5290000	6290000	4460102	5460102	6460102
2012	6	5416000	6416000	7416000	4873581	5873581	6873581
2013	7	7156000	8156000	9156000	5287060	6287060	7287060
2014	8	6808200	7808200	8808200	5700538	6700538	7700538
2015	9	6460400	7460400	8460400	6114017	7114017	8114017
2016	10	6112600	7112600	8112600	6527496	7527496	8527496
2017	11	5764800	6764800	7764800	6940975	7940975	8940975
2018	12	5417000	6417000	7417000	7354454	8354454	9354454
2019	13	9256000	10256000	11256000	7767933	8767933	9767933
2020	14	7850000	8850000	9850000	8181411	9181411	10181411
2021	15	9217000	10217000	11217000	8594890	9594890	10594890
2022	16	13976000	14976000	15976000	9008369	10008369	11008369
2023	17	4092000	5092000	6092000	9421848	10421848	11421848
المجموع	153	106331000	124331000	142331000			

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.

جدول(7): يوضح القيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2024 إلى 2030 وفقاً لنموذج (Static HFLSR):

السنة (x)	Year Index	Pred_Lower	Pred_Center	Pred_Upper
2024	18	9835327	10835327	11835327
2025	19	10248806	11248806	12248806
2026	20	10662284	11662284	12662284
2027	21	11075763	12075763	13075763
2028	22	11489242	12489242	13489242
2029	23	11902721	12902721	13902721
2030	24	12316200	13316200	14316200

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.



شكل (5): يوضح القيم الفعلية والقيم المتوقعة والقيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية وفقاً لنموذج (Static HFLSR) ومقاييس المسافة الضبابية:

يوضح الجزء العلوي من شكل (5) إتجاهاً تصاعدياً منتظماً لمخصص تعويضات مجمع الصناديق الحكومية ومستقراً عبر السنوات التاريخية، مع نطاق ضبابي ثابت بقيمة (± 1000000) ، كما تظهر القيم المتنبأ بها للفترة (2024 - 2030) استمراراً لهذا الاتجاه التصاعدي التدريجي، وهو ما يشير إلى سلوك مستقر للنموذج ومستوى منخفض من عدم اليقين. وتظهر قيمة معامل التحديد الضبابي $(Fuzzy R^2 = 0.5492)$ إلى ارتباط متوسط القوة بين القيم التاريخية والقيم المتوقعة، مما يعني أن الانتشار الثابت الضبابي يخفف من درجة مرونة النموذج في تمثيل البيانات الفعلية. أما الجزء السفلي من شكل (5) فيعرض مقياسي المسافة الضبابية D_t^2 ، D_{mean}^2 حيث تتجه قيمهما إلى الانخفاض في معظم السنوات مع درجة من الاستقرار النسبي، باستثناء ارتفاع ملحوظ عام 2022 مما يشير إلى زيادة مؤقتة في تشتت القيم. ويظهر هذا النمط أن نموذج (Static HFLSR) يتمتع باستقرار جيد في التنبؤ، إلا أنه أقل حساسية للتقلبات الحقيقية التي قد تطرأ على البيانات.

2-2- نموذج الانحدار الضبابي الهجين الديناميكي (Dynamic HFLSR):

في نموذج الانحدار الضبابي الهجين الديناميكي (Dynamic HFLSR) يفترض أن العلاقة بين \tilde{Y} ، X تتغير مع الزمن، ولذلك نكون بصدد نموذج ديناميكي (متغير) مبني على الانحرافات، حيث يتم إضافة متغير الانحرافات بين السنوات المتتالية في النموذج، وتأخذ معادلة الانحدار الشكل التالي:

$$\tilde{Y}_i = \tilde{A}_0 + \tilde{A}_1 t_i + \tilde{A}_2 \Delta_i + \tilde{\epsilon}_i$$

ويتم تطبيق هذا النموذج وفق الخطوات الآتية:

- تكويد المتغير المستقل (X) من (0 إلى 17)
 - إضافة متغير الانحرافات ($\Delta_i = Y_i - Y_{i-1}$) إلى النموذج.
 - ويكون نموذج المراكز الديناميكي المقدر على الصورة التالية:
- $$\hat{y}_i = 2700268.02 + 484314.46 * t_i + 0.63 * \Delta_i$$
- حيث t_i : كود السنة ، Δ_i : الانحرافات
- $$\hat{y}_i = 2700268.02 + 484314.46 * t_i + 0.63 * \Delta_i$$
- إيجاد بواقي النموذج $r_i = y_i - \hat{y}_i$ ، $s_i^{obs} = |r_i|$ ، حيث أن: s_i^{obs} ترمز إلى الانتشار الفعلي (spread observation).
 - يتم إيجاد الحدود الفعلية كالتالي: (الحد الأدنى L_i ، $L_i^{obs} = y_i - s_i^{obs}$ ، والحد المركزي $C_i^{obs} = y_i$ ، والحد الأعلى U_i ، $U_i^{obs} = y_i + s_i^{obs}$).
 - وبافتراض نمطاً خطياً للانتشار $| [1 \quad t_i \quad \Delta_i] |$ ، $s^{obs} \approx A\gamma$ ، وباستخدام طريقة المربعات الصغرى غير السالبة (Non-negative Least Squares, NNLS)

(Katharine et al., 2025; Lawson & Hanson, 1974; Slawski & Hein, 2013)

يمكن تقدير معاملات النموذج مع ضمان أن تكون جميع القيم المقدرة غير سالبة، مما يتماشى مع طبيعة البيانات الضبابية ومخصصات التعويضات التي لا يمكن أن تأخذ قيماً سالبة.

$$\min_{\gamma \geq 0} \|A\gamma - s^{obs}\|_2^2, \quad \text{subject to } \gamma \geq 0$$

يمثل $A\gamma$: الانتشار المتوقع من النموذج. وتتمثل عملية المعايرة في إيجاد القيم المثلى لـ γ التي تقلل الفرق (أو الخطأ) بين الانتشار المتوقع $A\gamma$ والانتشار الملاحظ فعلياً s^{obs} .

- وبالتالي يتم الحصول على تقدير معاملات γ كما يلي:

$$\hat{\gamma} = [\hat{\gamma}_0, \hat{\gamma}_1, \hat{\gamma}_2]^T$$

- يتم إيجاد القيم المتوقعة (spread) من العلاقة التالية: $\hat{s} = A\hat{\gamma}$ ، موضح ذلك في جدول (8).

جدول (8): يوضح القيم الفعلية والقيم المتوقعة بحدودها (Lower, Center, Upper) لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2006: 2023 وفقاً لنموذج (Dynamic HFLSR):

السنة	القيم الفعلية (Center)	Δ_i	s_i^{obs}	\hat{s}	\hat{y}_{ic}	\hat{y}_{il}	\hat{y}_{iu}
2006	2500000	0	200268	259375	2700268	2440893	2959643
2007	3288000	788000	390926	306091	3678926	3372835	3985017
2008	3512000	224000	297421	352807	3809421	3456614	4162228
2009	4881000	1369000	131039	399522	5012039	4612516	5411561
2010	5334000	453000	412289	446238	4921711	4475472	5367949
2011	5290000	-44000	195763	492954	5094237	4601283	5587192
2012	6416000	1126000	103461	539670	6312539	5772869	6852209
2013	8156000	1740000	973960	586386	7182040	6595654	7768426
2014	7808200	-347800	1451605	633102	6356595	5723493	6989697
2015	7460400	-347800	619490	679818	6840910	6161092	7520727
2016	7112600	-347800	212624	726534	7325224	6598690	8051758
2017	6764800	-347800	1044738	773250	7809538	7036289	8582788
2018	6417000	-347800	1876853	819965	8293853	7473887	9113818
2019	10256000	3839000	1148712	866681	11404712	10538030	12271393
2020	8850000	-1406000	251369	913397	8598631	7685234	9512028
2021	10217000	1367000	605558	960113	10822558	9862445	11782671
2022	14976000	4759000	1541193	1006829	13434807	12427978	14441636
2023	5092000	-9884000	359008	1053545	4732992	3679447	5786536

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.

■ إيجاد القيم المستقبلية (القيم المتنبأ بها من 2024-2030) وفقاً لنموذج (Dynamic HFLSR)

$$\hat{S}_{future} = A_{future} \hat{V}$$

وفقاً للخطوات التالية:

- 1- تقدير الانحرافات المستقبلية (Δ_{future})، وذلك من خلال نمذجة Δ كدالة خطية في الزمن، أى نفترض أن Δ_i نفسها تتغير خطياً مع الزمن t_i كالتالى:

$$\Delta_i \approx b_0 + b_1 t_i$$

حيث يتم تقدير معاملات الانحدار \hat{b}_0 و \hat{b}_1 .

- 2- حساب قيم Δ_{future} للسنوات المستقبلية كالتالى:

$$\hat{\Delta}_{future} = \hat{b}_0 + \hat{b}_1 t_{future}$$

3- بناء مصفوفة A_{future} على النحو التالي:

$$A_{future} = [1, t_{future}, \hat{\Delta}_{future}]$$

4- التنبؤ بالقيم المستقبلية وبمعلومية \hat{r} من العلاقة التالية:


$$\hat{S}_{future} = A_{future} \hat{r}$$

وموضح ذلك في جدول (9).

جدول(9): يوضح القيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية في الفترة من 2024 إلى 2030 وفقاً لنموذج (Dynamic HFLSR):

السنة (x)	Year Index	Delta_pred	Pred_Center	\hat{s}	Pred_Lower	Pred_Upper
2024	18	-928686	10835327	1100261	9735066	11935588
2025	19	-1041601	11248806	1146977	10101829	12395782
2026	20	-1154515	11662284	1193693	10468592	12855977
2027	21	-1267429	12075763	1240408	10835355	13316172
2028	22	-1380344	12489242	1287124	11202118	13776366
2029	23	-1493258	12902721	1333840	11568881	14236561
2030	24	-1606172	13316200	1380556	11935644	14696756

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.



شكل (6): يوضح القيم الفعلية والقيم المتوقعة والقيم المتنبأ بها لمخصص تعويضات مجمع الصناديق الحكومية وفقاً لنموذج (Dynamic HFLSR) ومقاييس المسافة الضبابية:

يظهر الجزء العلوي من شكل (6) اتجاهًا تصاعدياً لمخصص تعويضات مجمع الصناديق الحكومية مع أقصى قيمة في عام 2022، ثم عادت للاستقرار في عام 2023، بينما تعكس القيم المستقبلية المتنبأ بها خلال فترة (2024- 2030) استمرار الاتجاه التصاعدي ضمن نطاق ضبابي محدود، وهو ما يدل على مستوى مقبول من عدم اليقين. كما يلاحظ تحسن ملحوظ في دقة نموذج (Dynamic HFLSR) وقدرته التمثيلية للعلاقة بين القيم التاريخية والقيم المتوقعة، حيث ارتفع

معامل التحديد الضبابي إلى ($Fuzzy R^2 = 0.8874$) مقارنة بنموذج (Static HFLSR) الذي بلغ فيه 0.5492. ويبين الجزء السفلي من شكل (6) مقاييس المسافة الضبابية، إذ يظهر مقياس D_{mean}^2 تذبذباً منخفضاً مع وصوله إلى أعلى قيمة في عام 2022، وهو ما يتسق مع القمة الظاهرة في الجزء العلوي، مشيراً إلى زيادة مؤقتة في تباين البيانات أو في درجة عدم اليقين الضبابي. في حين نجد أن مقياس D_i^2 يتسم بقدر أكبر من الاستقرار، مما يعزز الدلالة على جودة النموذج واستقراره التنبؤي في تمثيل مخصص التعويضات عبر الزمن.

3- مقاييس دقة التنبؤ وفقاً للنماذج المختلفة:

جدول (10): يوضح مقاييس دقة التنبؤ وفقاً للنماذج المختلفة:

	RMSE	MAE	MAPE	R^2
ANFIS	1881922	1132343	15.918%	0.5773681
Static HFLSR	1943340.87	1275382.80	19.51%	0.5492
Dynamic HFLSR	868364.2	684105.4	9.495%	0.8874

المصدر: من إعداد الباحث باستخدام برنامج التحليل الإحصائي R.

يتضح من جدول (10) أن نموذج الانحدار الضبابي الديناميكي (Dynamic HFLSR) هو الأكثر دقة وملاءمة للتنبؤ بقيمة مخصص تعويضات مجمع الصناديق الحكومية مقارنة بكل من نموذج الاستدلال العصبي الضبابي التكيفي (ANFIS) ونموذج الانحدار الضبابي الثابت (Static HFLSR). فقد حقق النموذج أفضل أداء إحصائي، حيث سجل أعلى قيمة لمعامل التحديد الضبابي ($Fuzzy R^2 = 0.8874$)، مما يعكس قدرة قوية على تفسير التباين الضبابي في البيانات. كما حقق أقل قيم لمقاييس الخطأ (MAPE, MAE, RMSE)، مما يدل على مستوى عالي من دقة التنبؤ. إضافة إلى ذلك، فإن خاصية الانتشار الديناميكي تمكنه من تمثيل التغيرات السنوية في البيانات بشكل أكثر واقعية مقارنة بالنماذج الأخرى.

نتائج الدراسة:

تتمثل أهم النتائج التي توصلت إليها الدراسة فيما يلي:

- أظهرت النتائج كفاءة النطاق الضبابي الديناميكي في التعامل مع الغموض وعدم اليقين الموجود في البيانات المالية، مما يجعله أداة فعالة في تحسين دقة التنبؤات ودعم قرارات إدارة المخاطر في مجالات التخطيط المالي الطويل المدى، مما يجعلها تؤسس لاتجاه بحثي يمكن الاعتماد عليه في المستقبل.
- أوضحت نتائج تطبيق نموذج الانحدار الضبابي الديناميكي (Dynamic HFLSR) تحسناً ملحوظاً في دقة التقدير وقدرة النموذج التفسيرية مقارنة بالنموذج ذات النطاق الثابت (Static HFLSR) ونموذج الاستدلال العصبي الضبابي التكيفي (ANFIS)، وقد انعكس ذلك من خلال الارتفاع الكبير في معامل التحديد الضبابي ($Fuzzy R^2$)، حيث بلغت قيمته 0.8874 مقارنة بـ 0.5492 و 0.5773 على التوالي، مما يؤكد قدرة النموذج الديناميكي على تفسير ما يقرب من 89% من التباين في البيانات، كما حقق أقل قيم لمقاييس الخطأ (MAPE, MAE, RMSE).

التوصيات:

وتوصى الدراسة بتطبيق نموذج الانحدار الضبابي الديناميكي (Dynamic HFLSR) للتنبؤ بقيمة مخصص التعويضات، وذلك لما أظهره من تفوق في مستوى الدقة والأداء الإحصائي، وبالتالي يحسن من طريقة إدارة مخاطر الصناديق الحكومية ومن ثم تقليل الخطأ في تقدير قيمة المخصص. كما توصى الدراسة بإمكانية تعميم تطبيق هذا النموذج على مشاكل تنبؤ أخرى في المجال المالي والتأميني.

المراجع:

أولاً: المراجع العربية:

- (1) خليل، أحمد عبد الرحيم، صفية أحمد أبو بكر، هشام عبد المجيد عبد الله، حمدي فايز فرحات (2020) "التنبؤ بمعدل الخسارة لفرع تأمين الطيران باستخدام الشبكات العصبية الفازية بالتطبيق على شركة مصر للتأمين"، المجلة العلمية لكلية التجارة (أسبوط)، ع(68)، 91-114.
- (2) الخواجة، حامد عبدالقوي محمد (2014) "نموذج كمي لتقدير مخصص التعويضات تحت التسوية بسوق التأمين السعودي"، جامعة بور سعيد، كلية التجارة، مجلة البحوث المالية والتجارية، ع1.
- (3) درويش، محمد محمود هاشم (2021) "التنبؤ بفائض النشاط التأميني لشركات تأمينات الممتلكات والمسئولية بالسوق المصري باستخدام النماذج المضطربة الفازية" مجلة البحوث المالية، بورسعيد، العدد 1.
- (4) شاهين، نها عبد اللطيف عبد الحميد (2020) "قياس مخاطر إستثمارات صناديق التأمين الحكومي بالتطبيق على صندوق أرباب العهد" مجلة البحوث التجارية المعاصرة- سوهاج، المجلد 34.
- (5) عباس، ريهام عبد الرؤوف محمد (2022) "التنبؤ بالملاءة المالية لنظام التأمين الاجتماعي بجمهورية مصر العربية باستخدام نماذج السلاسل الزمنية الفازية (Fuzzy Time Series Models)" رسالة دكتوراه، كلية التجارة، جامعة القاهرة.
- (6) عبد الحميد، محمد إبراهيم محمد (2015) "التنبؤ باستخدام السلاسل الزمنية الفازية ومقارنتها بنماذج بوكس وجنكيز" رسالة ماجستير، كلية التجارة، جامعة المنصورة.
- (7) عطا، محمد محمد محمد، حسانين، علي سيد بخيت & علي، فاطمه حربي (2022) "استخدام الانحدار الخطي الضبابي في التنبؤ بمخصص التعويضات تحت التسوية في شركات التأمين المصرية"، مجلة البحوث التجارية المعاصرة، 36(4)، 29-44.
- (8) علي، فاطمة حربي، محمد محمد محمد عطا، علي سيد بخيت حسانين (2023) "أسلوب مقارنة للتنبؤ بمخصص التعويضات تحت التسوية بين نموذج الانحدار الخطي المتعدد OLS ونموذج Bayes بالتطبيق على شركات التأمين المصرية"، مجلة سوهاج لشباب الباحثين، 3(4)، 91-101.
- (9) قرار مجلس الوزراء رقم (39) لسنة 2019 بإصدار اللائحة التنفيذية لقانون الضريبة على الدخل الصادر بالقانون رقم (24) لسنة 2018.
- (10) الكتاب الإحصائي السنوي عن نشاط التأمين خلال الأعوام المالية (2006-2023)، الهيئة العامة للرقابة المالية.

-
-
- (11) محمد، أسماء خلف سيد، نادية على شعيب، محمد عبد المحسن محمد (2023) "التنبؤ بمخصص التعويضات تحت التسوية بفرع تأمين البترول باستخدام نموذج الشبكات العصبية المواءم بالفازية ANFIS"، المجلة العلمية لكلية التجارة، جامعة أسيوط، 43(77)، 15-45.
- (12) مظهر، مصطفى كمال إسماعيل، (1999) "صندوق التأمين الحكومي لضمان أرباب العهد: نموذج تأمين خيانة الأمانة والاختلاس في ج. م. ع.: رؤية مستقبلية لدور أكثر إيجابية وفاعلية" المجلة المصرية للدراسات التجارية، كلية التجارة، جامعة المنصورة، المجلد الثالث والعشرون، العدد الثاني، ص: 498.
- (13) المعداوي، جيهان مسعد، محمد مسعد المعداوي (2020) "نموذج مقترح لتقدير مخصص التعويضات تحت التسوية"، جامعة دمياط، كلية التجارة، المجلة العلمية للدراسات والبحوث المالية والتجارية، المجلد الأول، العدد الثاني، الجزء الثاني.
- (14) موقع الهيئة العامة للرقابة المالية، 2019: www.fra.cov.eg.

ثانياً: المراجع الأجنبية:

- 1) Apaydin, A., & Baser, F. (2010). Hybrid fuzzy least-squares regression analysis in claims reserving with geometric separation method. Insurance: Mathematics and Economics, 47(2), 113–122. <https://doi.org/10.1016/j.insmatheco.2010.07.001>
- 2) Ayyub, B. M., & Gupta, M. M. (Eds.). (1997). Uncertainty analysis in engineering and sciences: Fuzzy logic, statistics, and neural network approach (Vol. 11). Springer Science & Business Media.
- 3) Chang, Y.-H. O. (2001). Hybrid fuzzy least-squares regression analysis and its reliability measures. Fuzzy Sets and Systems, 119(2), 225–246. [https://doi.org/10.1016/S0165-0114\(99\)00092-5](https://doi.org/10.1016/S0165-0114(99)00092-5)
- 4) Enders, C. K. (2010). Applied Missing Data Analysis. Guilford Press.
- 5) Fang, H. (2012). Adaptive neuro fuzzy inference system in the application of the financial crisis forecast. International Journal of Innovation, Management and Technology, 3(3), 250.
- 6) Giovanis, E. (2010). Application of Adaptive Neuro-Fuzzy Inference System in the Prediction of Economic Crisis Periods in USA. International Journal of Human and Social Science, 5(14), 899-904.
- 7) Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and Practice (2nd ed.). OTexts. Retrieved from <https://otexts.com/fpp2/>
- 8) Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man, and Cybernetics, 23(3), 665–685. <https://doi.org/10.1109/21.256541>
- 9) Jimenez, L. (2016). Fuzzy regression models: Theory and applications. International Journal of Approximate Reasoning, 72, 58–72.

-
-
- 10) Kahya, E. (2005). A new unidimensional search method for optimization: Linear interpolation method. Applied Mathematics and Computation, 171(2), 912-926.
 - 11) Karaboga, D., & Kaya, E. (2019). Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. Artificial Intelligence Review, 52(4), 2263-2293.
 - 12) Katharine M. Mullen, Ivo H. M. van Stokkum (2025). The Lawson-Hanson Algorithm for Non-Negative Least Squares (NNLS), Version 1.6, Date/Publication 2024-10-23 06:30:02 UTC.
 - 13) Lawrence, L. Lapin (1993) "Statistics for Modern Business Decisions", Sixth Edition. Harcourt Brace College Publishers.
 - 14) Lawson, C. L., & Hanson, R. J. (1974). Solving Least Squares Problems. Prentice-Hall.
 - 15) Little, R. J. A., & Rubin, D. B. (2019). Statistical Analysis with Missing Data (3rd ed.). Wiley.
 - 16) Mullen, K. M. (2023). nnls: Solve Non-Negative Least Squares Problems (R package version 1.4). CRAN. <https://CRAN.R-project.org/package=nnls>
 - 17) Müller, K., & Wickham, H. (2023). tibble: Simple data frames (R package version 3.2.1). CRAN. <https://CRAN.R-project.org/package=tibble>
 - 18) Pakdel, M., Razzaghnia, T., Fathi, K., & Mostafaei, A. (2025). Estimation of Fuzzy Regression Parameters With ANFIS and Bayesian Methods. Engineering Reports, 7(1), e13086.
 - 19) Pedersen, T. L. (2020). patchwork: The composer of plots (R package version 1.1.2). CRAN. <https://CRAN.R-project.org/package=patchwork>
 - 20) R Core Team (2022) R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna. <https://www.R-project.org>
 - 21) Slawski, M., & Hein, M. (2013). Non-negative least squares for high-dimensional linear models: Consistency and sparse recovery without regularization. Electronic Journal of Statistics, 7, 3004–3056.
 - 22) Tanaka, H., & Asai, K. (1982). Linear regression analysis with fuzzy model. IEEE Transactions on Systems, Man, and Cybernetics, 12(6), 903–907. Linear Regression Analysis with Fuzzy Model | IEEE Journals & Magazine | IEEE Xplore

-
-
- 23) Wickham, H. (2016). ggplot2: Elegant graphics for data analysis (R package version 3.4.3). Springer-Verlag New York. <https://CRAN.R-project.org/package=ggplot2>
 - 24) Wickham, H., & Seidel, D. (2023). scales: Scale functions for visualization (R package version 1.2.1). CRAN.<https://CRAN.R-project.org/package=scales>
 - 25) Wickham, H., François, R., Henry, L., & Müller, K. (2023). dplyr: A grammar of data manipulation (R package version 1.2.1). CRAN. <https://CRAN.R-project.org/package=dplyr>
 - 26) Woundjiague, A., Waweru, M. R., & Mbele Bidima, M. L. D. (2019). A fuzzy least-squares estimation of a hybrid log-Poisson regression and its goodness of fit for optimal loss reserves in insurance. International Journal of Fuzzy Systems, 21(3), 930–944. <https://doi.org/10.1007/s40815-018-0564-6>

Predicting the Loss Reserve of Government Fund Pools Using Fuzzy Artificial Intelligence Techniques

Abstract:

This research aims to predict the loss reserve of government fund pools by applying and comparing the performance of three predictive models: Adaptive Neuro-Fuzzy Inference System (ANFIS), Static Hybrid Fuzzy Least Squares Regression (Static HFLSR), and Dynamic Hybrid Fuzzy Least Squares Regression (Dynamic HFLSR) for estimating the annual loss reserve based on historical data for the period from 2006 to 2023.

The results indicated that the Dynamic HFLSR model performed best in terms of statistical accuracy, with Fuzzy $R^2 = 0.8874$, $RMSE = 868364.2$, $MAE = 684105.4$, and $MAPE = 9.49\%$, while the ANFIS model performed well in handling nonlinear patterns, its accuracy was lower than the Dynamic HFLSR model. The Static HFLSR model showed average performance.

The study recommends applying the Dynamic HFLSR model to predict the loss reserve of government fund pools due to its superior accuracy and statistical performance. This approach improves the management of government fund risks and reduces estimation errors in loss reserve. Furthermore, the study suggests extending the model's application to other forecasting challenges in the financial and insurance sectors.

Keywords: Loss Reserve, Government Fund Pools, ANFIS, HFLSR.