



إشتقاق معادلة تجريبية لتقدير العزم الأقصى للكمرات الخرسانية المسلحة باستخدام الشبكات العصبية الاصطناعية (ANN) بالاعتماد على بيانات الكود الأمريكي (ACI)

محمد العربي المحروق

كلية الهندسة صبراتة جامعة صبراتة

mohamed.elmahroug@sabu.edu.ly

Derivation of an Empirical Equation for Estimating the Ultimate Moment Capacity of Reinforced Concrete Beams Using Artificial Neural Networks (ANN) Based on ACI-318 Code Data

Mohamed Elarbi Mahroug

Faculty of Engineering, Sabratha University, Sabratha, Libya

تاريخ الاستلام: 2026/01/12 - تاريخ المراجعة: 2026/02/07 - تاريخ القبول: 2026/02/19 - تاريخ النشر: 2026/03/18

الملخص

تهدف هذه الدراسة إلى استخدام تقنيات الذكاء الاصطناعي، وبالأخص الشبكات العصبية الاصطناعية، لاشتقاق معادلة تجريبية لحساب عزم الانحناء في الكمرات الخرسانية المسلحة. ونظرًا لأهمية حساب العزم بدقة في التصميم الإنشائي، تم اعتماد معادلات الكود الأمريكي (ACI) كمرجع لمقارنة النتائج والتحقق من دقة النموذج المقترح. تم إنشاء قاعدة بيانات مكونة من (60) كمرة خرسانية مسلحة، تمثل نطاقًا واسعًا من الخصائص الهندسية والميكانيكية، مثل عرض الكمرة والعمق الفعال، مقاومة ضغط الخرسانة، إجهاد خضوع حديد التسليح، ومساحة التسليح. وقد استُخدمت هذه البيانات في تدريب واختبار عدة نماذج من الشبكات العصبية الاصطناعية بهدف التوصل إلى النموذج الأكثر دقة واستقرارًا. أظهرت نتائج التحليل أن النموذج العصبي المختار حقق توافقًا عاليًا مع القيم المرجعية المستخرجة من معادلات الكود الأمريكي، حيث سجل قيمًا مرتفعة لمعامل التحديد (R^2) وقيمًا منخفضة لمتوسط الخطأ المطلق (MAE). وبناءً على ذلك، تم استخراج معادلة تجريبية نهائية في صورة لوغارتمية، تُمكن من حساب عزم الانحناء مباشرة دون الحاجة إلى تشغيل نموذج الشبكة العصبية. تشير نتائج الدراسة إلى أن الشبكات العصبية الاصطناعية تمثل أداة فعالة ودقيقة في نمذجة السلوك الإنشائي للكمرات الخرسانية المسلحة، وأن المعادلة التجريبية المستخلصة يمكن أن تُستخدم كوسيلة مساعدة في التصميم والتحقق الهندسي، ضمن نطاق البيانات التي تم تدريب النموذج عليها.

مفاتيح الكلمات: تحليل الحساسية، الشبكات العصبية، السلوك الإنشائي، الكمرات الخرسانية، العلاقات غير الخطية، والنمذجة العددية.

Abstract

This project aims to utilize Artificial Neural Networks (ANNs) to derive an empirical equation for calculating the flexural moment of reinforced concrete beams. Due to the importance of accurate flexural moment estimation in structural design, the American Concrete Institute (ACI) code equations were adopted as a reference to validate and assess the accuracy of the proposed model. A database consisting of eighty (60) reinforced concrete beams was developed, covering a wide range of geometric and mechanical properties, including beam

width, effective depth, concrete compressive strength, steel yield strength, and reinforcement area. These data were used to train and test several ANN models in order to identify the most accurate and stable configuration. The results demonstrated a strong agreement between the flexural moments predicted by the selected ANN model and those calculated using the ACI code equations, as indicated by high values of the coefficient of determination (R^2) and low values of the mean absolute error (MAE). Based on the final ANN model, a logarithmic empirical equation was extracted, enabling direct calculation of the flexural moment without the need to run the neural network model. The findings of this study confirm that artificial neural networks are an effective and reliable tool for modeling the flexural behavior of reinforced concrete beams. Moreover, the derived empirical equation can serve as a practical and simplified method for engineering calculations and design verification within the range of data used in this study.

Keywords: Sensitivity Analysis, Neural Networks, Structural Behaviour, Concrete Beams, Nonlinear Relationships, Numerical Modelling.

1. المقدمة

تُعد الكمرات الخرسانية المسلحة من العناصر الإنشائية الأساسية في المباني والمنشآت الهندسية، حيث تتحمل بصورة رئيسية قوى الانحناء الناتجة عن الأحمال المختلفة. وفي خلال العقود الماضية، أُجريت العديد من الدراسات [1-9] بهدف دراسة السلوك الانحنائي للكمرات الخرسانية المسلحة. ويُعتبر حساب عزم الانحناء بدقة من أهم مراحل التصميم الإنشائي، لما له من تأثير مباشر على أبعاد المقطع الخرساني، كمية ونوع التسليح، ومستوى الأمان والكفاءة الاقتصادية للمنشأ [6]. ، [4] إلا أن السلوك الحقيقي للكمرات الخرسانية المسلحة يتسم بدرجة عالية من التعقيد نتيجة الطبيعة غير الخطية للخرسانة، حدوث التشققات، وتغير صلابة المقطع مع زيادة الحمل، مما يجعل التنبؤ الدقيق بعزم الانحناء تحديًا هندسيًا ملحوظًا [5]. تعتمد الطرق التقليدية في الأكواد التصميمية على نماذج تحليلية ومعادلات نظرية مبنية على فرضيات تبسيطية، مثل السلوك المرن الخطي للمواد والتوزيع المثالي للإجهادات، وقد أظهرت العديد من الدراسات [4-6] أن هذه الفرضيات لا تعكس دائمًا السلوك الحقيقي للكمرات الخرسانية المسلحة، خاصة في مراحل ما بعد التشقق أو عند الاقتراب من حالة الانهيار، مما يؤدي إلى فروق واضحة بين القيم النظرية والنتائج التجريبية. في هذا الإطار، اتجهت الأبحاث الحديثة إلى توظيف تقنيات الذكاء الاصطناعي والحوسبة اللينة كبداية فعالة للطرق التحليلية التقليدية. فقد استخدمت دراسة [8] تقنية الشبكات العصبية الاصطناعية (Artificial Neural Networks) لتحليل سلوك الكمرات الخرسانية المسلحة الخالية من كانات القص، وأظهرت النتائج تفوق نماذج الشبكات العصبية على نماذج الأكواد التقليدية في التنبؤ بحمل التشقق الأول، ومقاومة الانحناء، ومقاومة القص، مع كفاءة حسابية أعلى. وفي السياق ذاته، أظهرت دراسة علمية سابقة [4] استخدام نماذج عديدة متقدمة للتنبؤ بالسلوك الانحنائي للكمرات المسلحة بقضبان الفايبر (FRP (Fiber Reinforced Polymer) ، مع الأخذ في الاعتبار عدم خطية الخرسانة وتأثير التشققات. وأظهرت النتائج تحسناً ملحوظاً في دقة حساب الانحرافات وقدرة العزم مقارنة بالطرق التقليدية، مع التأكيد على الطبيعة الهشة لهذا النوع من التسليح. كما تناولت دراسات أخرى مسألة التنبؤ بالهبوط وعلاقته بالسلوك الانحنائي للكمرات الخرسانية المسلحة، فقد أشار الباحثان [2] إلى محدودية الطرق المعتمدة على مفهوم

عزم القصور الذاتي الفعال في تمثيل السلوك الحقيقي للكمرات، واقترحا استخدام الشبكات العصبية الاصطناعية ANN كأداة أكثر دقة لمعالجة العلاقات غير الخطية بين الإجهاد والانفعال. وفي الإطار ذاته، كشفت دراسة [1] من خلال مراجعة شاملة أن تطبيقات الذكاء الاصطناعي في التنبؤ بالسلوك الانحنائي لا تزال غير شاملة، واقترحوا نماذج تعتمد على الشبكات العصبية الاصطناعية ANN لتحسين دقة التنبؤ. بالإضافة إلى ذلك، أظهرت دراسة [5] كفاءة الشبكات العصبية الاصطناعية ANN في التنبؤ بالخصائص الميكانيكية للخرسانة، مما يدعم إمكانية توظيفها في تحليل السلوك الإنشائي للعناصر الخرسانية المسلحة. كما تناول الباحثان [6] السلوك الانحنائي للكمرات الخرسانية المستمرة المسلحة بقضبان FRP، وأشاروا إلى الحاجة لتطوير نماذج أكثر دقة من تلك المعتمدة في الأكواد الحالية.


بناءً على ما سبق، يتضح وجود فجوة بحثية تتمثل في الحاجة إلى نماذج تنبؤية دقيقة وموثوقة قادرة على تمثيل السلوك الحقيقي للكمرات الخرسانية المسلحة، خاصة فيما يتعلق بعزم الانحناء، مع الأخذ في الاعتبار تأثير الخصائص الهندسية والميكانيكية المختلفة. ومن هنا، يهدف هذا البحث إلى تطوير نموذج قائم على الشبكات العصبية الاصطناعية ANN للتنبؤ بعزم الانحناء للكمرات الخرسانية المسلحة، وتقييم أدائه مقارنة بالطرق التحليلية التقليدية، بما يساهم في تحسين دقة التصميم الإنشائي وتقديم أداة عملية داعمة للمهندسين المصممين.

2. الإطار النظري ومنهجية البحث

1.2. الشبكات العصبية الاصطناعية (ANN)

يهدف هذا البحث إلى تقديم عرض أكاديمي متكامل للأسس النظرية والتطبيقية لاستخدام الشبكات العصبية الاصطناعية في اشتقاق معادلة تجريبية لحساب العزم، مع توضيح البنية الرياضية للشبكة، وآلية التدريب، ومعايير التقييم، وصولاً إلى الصيغة العامة للمعادلة المستخلصة.

تعتمد هذه الدراسة على شبكة عصبية اصطناعية من النوع متعدد الطبقات ذات التغذية الأمامية (Multilayer Feed forward Neural Network)، والتي تُعد من أكثر البنى استخداماً في التطبيقات الهندسية. تتكون الشبكة من ثلاث طبقات رئيسية: طبقة الإدخال (Input Layer)، والطبقة المخفية (Hidden Layer)، وطبقة الإخراج (Output Layer) كما هو موضح بالشكل 1. تمثل طبقة الإدخال المتغيرات المستقلة المؤثرة في حساب العزم، بينما تضم الطبقة المخفية عدداً من الخلايا العصبية (Neuron) التي تقوم بمعالجة الإشارات الداخلة من خلال أوزان ترابطية وانحيازات محددة، ويتم تمرير ناتجها عبر دالة تنشيط غير خطية لتعزيز قدرة النموذج على التقريب الرياضي. أما طبقة الإخراج فهي المسؤولة عن إنتاج القيمة المتوقعة للعزم.



شكل (1) البنية العامة للشبكة العصبية

2.2. الصياغة الرياضية العامة للشبكة العصبية

يمكن التعبير عن عمل الوحدة الحسابية في الطبقة المخفية بالعلاقة:

$$Z_j = \sum_{i=1}^n w_{ij} x_i + b_j$$

حيث تمثل x_i مدخلات الشبكة العصبية، w_{ij} الأوزان التي تربط المدخل i بالعصب j ، b_j معامل الانحياز. أما معادلة الإخراج العامة للعزم فتعطى بالعلاقة:

$$M = \sum_{j=1}^m v_j H_j + b_0$$

حيث تمثل H_j مدخلات الشبكة العصبية، v_j الأوزان التي تربط المدخل j ، b_0 معامل ثابت. وبدمج العلاقتين، نحصل على الصيغة العامة للمعادلة التجريبية.

3.2. قاعدة البيانات وأعدادها

تعتمد كفاءة النموذج العصبي بشكل مباشر على جودة قاعدة البيانات المستخدمة. وقد تم إعداد البيانات وفق الخطوات التالية:

- جمع البيانات، تم الحصول على بيانات العزم من التحليل العددي، والمعادلات النظرية.
- تقسيم البيانات، تم تقسيم البيانات إلى مجموعات تدريب، تحقق، واختبار بنسب مناسبة.
- تطبيع البيانات، تم تطبيع البيانات لتقليل التباين العددي وتحسين عملية التدريب.

3. تدريب الشبكة العصبية وتقييم الأداء

1.3. تدريب واختبار الشبكة العصبية

تم تقسيم مجموعة البيانات المتاحة إلى مجموعتين رئيسيتين بهدف تطوير نموذج موثوق قائم على الشبكات العصبية الاصطناعية، حيث شملت ما يلي:


- **مجموعة التدريب:** تمثل 70% من إجمالي البيانات (42 ككرة) كما موضح بالجدول 1، وقد استُخدمت هذه المجموعة في تدريب الشبكة العصبية على تعلم الأنماط والعلاقات غير الخطية بين المتغيرات المدخلة، مثل الخصائص الهندسية للككرة، وبين المخرجات والمتمثل في العزم الأقصى. وخلال عملية مرحلة التدريب، جرى تحديث معاملات الشبكة العصبية بشكل تكراري اعتمادًا على خوارزمية التدريب المعتمدة، وذلك من خلال تقليل دالة الخطأ التي تمثل الفرق بين القيم المتوقعة الناتجة عن النموذج والقيم الفعلية المقاسة، إلى أن يتحقق أفضل توافق بينهما كما مبين بالشكل (2).

جدول 1 بيانات عدد من الكمرات تم استخدامها لتدريب الشبكة العصبية

Beam	b (mm)	d (mm)	f_y (Mpa)	f'_c (Mpa)	A_s (mm)	M_{ACI} (kN.m)	M_{ANN} (kN.m)	M_{ANN}/M_{ACI}
1	300	600	400	32	1734	347	330	0.95
2	350	650	420	38	2015	467	449	0.96
3	360	600	430	38	1922	420	402	0.95
4	320	500	450	36	1276	243	227	0.93
5	400	550	460	27	2423	490	461	0.94
6	280	560	470	30	2100	435	382	0.87
7	330	580	410	34	1850	370	352	0.95
8	310	620	435	33	1980	395	377	0.95
9	370	600	460	38	2250	480	458	0.95
10	340	590	420	35	2000	405	387	0.95
11	300	610	400	32	1800	340	322	0.94
12	350	630	430	38	2100	455	437	0.96
13	360	620	440	38	1950	430	409	0.95
14	320	510	450	36	1300	248	231	0.93
15	400	600	460	27	2450	494	466	0.94
16	280	560	470	30	2150	445	392	0.88
17	330	580	410	34	1870	375	357	0.95
18	310	620	435	33	2000	400	382	0.95
19	360	600	460	38	2270	485	463	0.95
20	340	600	420	35	2030	410	392	0.95
21	260	600	405	32	1750	345	328	0.95

جدول 1 (مستمر) بيانات عدد من الكمرات تم استخدامها لتدريب الشبكة العصبية

Beam	b (mm)	d (mm)	f_y (Mpa)	f'_c (Mpa)	A_s (mm)	M_{ACI} (kN.m)	M_{ANN} (kN.m)	M_{ANN}/M_{ACI}
22	300	610	410	33	1780	358	341	0.95
23	320	620	415	33	1800	368	351	0.95
24	300	620	420	34	1830	380	363	0.95
25	350	620	425	34	1850	390	374	0.95
26	320	630	430	35	1880	403	387	0.96
27	300	600	435	35	1900	413	398	0.96
28	260	605	440	36	1930	425	410	0.96
29	250	610	445	36	1950	435	421	0.96
30	300	615	450	37	1980	448	434	0.96
31	320	620	455	37	2000	458	445	0.97
32	260	600	460	32	1720	348	332	0.95
33	300	605	465	33	1740	355	338	0.95
34	320	610	470	33	1760	362	345	0.95
35	260	600	400	34	1780	360	342	0.95
36	300	605	405	34	1800	368	350	0.95
37	320	610	410	35	1830	375	357	0.95
38	300	615	415	35	1850	383	365	0.95
39	260	620	420	36	1880	390	373	0.95
40	300	625	425	36	1900	398	381	0.95
41	320	630	430	37	1930	405	389	0.96
42	250	600	435	37	1950	415	400	0.96

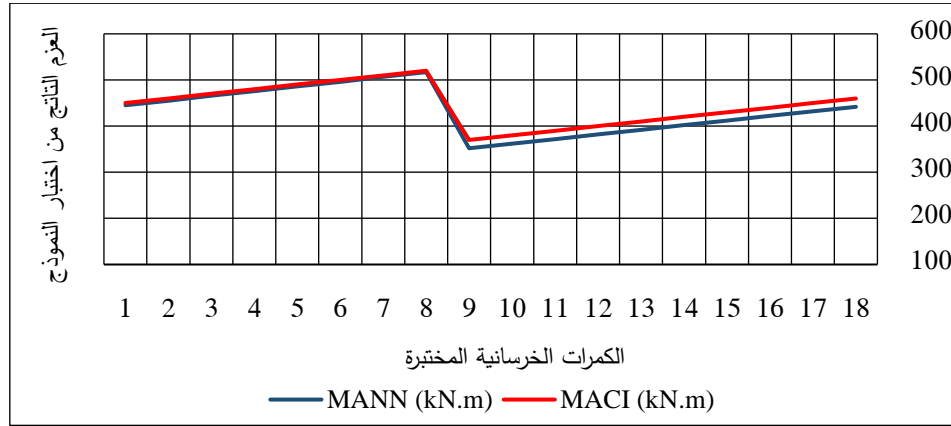


شكل (2) مقارنة بين قيم العزوم الناتجة من نموذج التدريب وتلك المقاسة بمعادلات الكود الأمريكي (ACI)

- مجموعة الاختبار والتحقيق: تم تخصيص حوالي 30% من إجمالي البيانات المتاحة، أي 18 كمرّة خرسانية، لتشكيل مجموعة الاختبار، كما هو موضح في الجدول 2. هذه المجموعة لم تُستخدم أثناء تدريب النموذج، وتمثل وسيلة لتقييم أدائه بشكل موضوعي وشامل. تساعد مجموعة الاختبار على مقارنة القيم التنبؤية للعزم الأقصى الناتجة عن الشبكة مع القيم الفعلية المقاسة للكمّرات، مما يوضح مدى قدرة النموذج على التنبؤ بالعزوم تحت مجموعة متنوعة من الظروف الهندسية المختلفة. كما تتيح مجموعة الاختبار أيضًا في التحقق من قابلية النموذج للتعميم، أي مدى كفاءته في تطبيق العلاقات المستخلصة على بيانات جديدة لم يسبق رؤيتها أثناء مرحلة التدريب كما هو موضح بالشكل (3). يساعد هذا الإجراء في تقليل احتمالية اعتماد النموذج على أنماط بيانات التدريب فقط، ويمنع حدوث ظاهرة فرط التعلّم (overfitting)، حيث قد يؤدي النموذج المدرب بشكل مكثف على بيانات محددة إلى نتائج ممتازة على بيانات التدريب فقط، بينما يتراجع الأداء عند التعامل مع بيانات جديدة وغير مألوفة. بفضل ذلك، يمكن للنموذج تمثيل العلاقة غير الخطية بين المدخلات وقيم العزم القصوى للكمّرات الخرسانية المسلحة بشكل موثوق دون الحاجة للاعتماد فقط على التجارب أو الطرق التقليدية.

جدول 2 بيانات عدد من الكمرات تم استخدامها لاختبار وتقييم قدرة النموذج

Beam	b (mm)	d (mm)	f_y (Mpa)	f'_c (Mpa)	A_s (mm)	M_{ACI} (kN.m)	M_{ANN} (kN.m)	M_{ANN}/M_{ACI}
1	300	610	435	35	2320	450	445	0.98
2	260	615	440	36	2350	460	455	0.98
3	250	620	445	36	2380	470	466	0.98
4	300	625	450	37	2400	480	476	0.99
5	320	630	455	37	2430	490	486	0.99
6	300	600	460	38	2450	500	496	0.99
7	260	605	465	38	2480	510	507	0.99
8	250	610	470	38	2500	520	517	0.99
9	300	615	400	37	1800	370	352	0.95
10	320	620	405	36	1830	380	362	0.95
11	300	625	410	35	1850	390	372	0.95
12	260	600	415	34	1880	400	382	0.95
13	250	605	420	33	1900	410	392	0.95
14	300	610	425	32	1930	420	402	0.95
15	320	615	430	32	1950	430	412	0.95
16	300	620	435	33	1980	440	422	0.95
17	260	625	440	34	2000	450	432	0.96
18	250	600	445	35	2030	460	442	0.96



شكل (3) مقارنة بين قيم العزوم الناتجة من نموذج الاختبار وتلك المقاسة بمعادلات الكود الأمريكي (ACI)

2.3. تقييم الأداء الإحصائي للنموذج

لتقييم أداء النموذج العصبي بشكل كمي، تم استخدام مجموعة من المؤشرات الإحصائية المعتمدة في الدراسات الهندسية، من أهمها:

- معامل التحديد (R^2): والذي يعبر عن نسبة التباين في قيم العزم التي يفسرها النموذج.
 - متوسط الخطأ المطلق (MAE): لقياس متوسط مقدار الانحراف بين القيم المتوقعة والمرجعية.
 - الجذر التربيعي لمتوسط مربع الخطأ ((RMSE): لتقييم شدة الخطأ وتأثره بالقيم الكبيرة.
- يوضح جدول 3 المؤشرات الإحصائية المستخدمة لتقييم أداء نموذج الشبكة العصبية. حيث أظهرت النتائج قيماً مرتفعة لمعامل التحديد (R^2) بلغت (0.998) لبيانات التدريب و(0.995) لبيانات الاختبار، مما يدل على قدرة النموذج العالية على تفسير التباين في قيم العزم الأقصى. كما سجلت مؤشرات الخطأ (RMSE) و (MAE) قيماً منخفضة، وهو ما يعكس دقة النموذج في التنبؤ وقوة قدرته على التعميم عند التعامل مع بيانات جديدة.

جدول 3 المؤشرات الإحصائية المعتمدة في الدراسات الهندسية

الاختبار	التدريب	نوع المؤشر الإحصائي
0.995	0.998	معامل التحديد (R^2)
1.35	1.12	جذر متوسط مربع الخطأ (RMSE)
1.05	0.89	متوسط الخطأ المطلق (MAE)

3.3. اشتقاق المعادلة التجريبية

بعد الانتهاء من تدريب الشبكة العصبية والتحقق من أدائه، تم استخراج القيم الخاصة بالأوزان ومعاملات الانحياز، تحويلها الى معادلة لوغاريتمية تجريبية واضحة يمكن استخدامها مباشرة في التصميم الهندسي.

$$\ln(M) = k_0 + \sum k_i \ln(x_i)$$

حيث تمثل k_i معاملات الانحدار المستخرجة من x_i (ANN) المتغيرات الأساسية.

أظهرت نتائج التدريب تقاربًا جيدًا بين القيم المتوقعة للعزم والقيم المرجعية المعتمدة في قاعدة البيانات. كما لوحظ انخفاض تدريجي في مقدار الخطأ مع زيادة عدد دورات التدريب حتى يصل إلى قيمة مستقرة، مما يعكس نجاح عملية التعلم واستقرار النموذج. كما بينت نتائج مجموعة التحقق أن النموذج يحتفظ بقدرته التنبؤية عند التعامل مع بيانات لم تُستخدم مباشرة في مرحلة التدريب، وهذا مؤشر مهم على كفاءة النموذج. من خلال اختبار عدة معادلات لوغاريتمية تعتمد على المتغيرات الأساسية (b, d, f'_c, f_y, A_s) إلا أن بعض المعادلات تعطي دقة تنبؤ منخفضة، مثل:

$$\ln)M(= 0.1 + 0.5\ln(b) + 0.3\ln(d) + 0.2\ln(f_y) + 0.1\ln(f'_c) + 0.4\ln(A_s)$$

$$\ln)M(= 0.15 + 0.5\log(b) + 0.3\log(d) + 0.2\log(f_y) + 0.1\log(f'_c) + 0.4\log(A_s)$$

من جانب آخر، أثبتت المعادلة اللوغاريتمية التالية قدرتها العالية في التنبؤ بقيمة العزم الأقصى بشكل جيد، مما أدى إلى اعتمادها كمعادلة تجريبية مناسبة وقابلة للاستخدام في التصميم الهندسي.

$$\ln)M(= -13.25 + 0.3\ln(b) + 1.15\ln(d) + 0.55\ln(f_y) + 0.1\ln(f'_c) + 0.85\ln(A_s)$$

4. تحليل الحساسية للمعادلة المعتمدة على الشبكات العصبية.

1.4 مفهوم تحليل الحساسية في نماذج (ANN)

تُعرّف الحساسية الجزئية على أنها معدل تغيّر ناتج النموذج بالنسبة لتغيّر أحد متغيرات الإدخال، مع ثبات بقية المتغيرات، ويُستخدم لتحديد:

- المتغيرات الأكثر تأثيرًا على المخرج.
- مدى استقرار النموذج.
- مصداقية النموذج من الناحية الهندسية.

رياضيًا، يمكن التعبير عنها بالمعادلة التالية (Sensitivity Equation):

$$S_i = \frac{\partial y}{\partial x_i} =$$

حيث S_i تمثل حساسية مخرجات النموذج بالنسبة للمتغير y ، x_i مخرجات الشبكة العصبية، x_i متغير الإدخال.

2.4 مناقشة نتائج تحليل الحساسية

تم تحليل الحساسية لتقييم تأثير متغيرات الإدخال على قيمة العزم (M_{ANN}) للكمرات الخرسانية المسلحة كما هو مبين بالجدول رقم 4. وقد شملت متغيرات الإدخال: مساحة حديد التسليح (A_s)، العمق الفعال (d)، عرض المقطع، (b) مقاومة الضغط للخرسانة (f'_c)، وإجهاد خضوع الحديد (f_y) والموضح بالجدول التالي. حيث أظهر التحليل أن التغير في مساحة حديد التسليح أدى إلى أكبر تأثير على قيمة العزم، مما يشير إلى أن الدقة في تحديد كمية الحديد له أهمية كبيرة للحصول على تنبؤ دقيق للعزم. كما بين التحليل أيضًا أن العمق الفعال للكمرات الخرسانية يُعد من المتغيرات ذات التأثير الكبير. ومن جانب آخر، فإن عرض المقطع ومقاومة الخرسانة له تأثيرًا متوسطًا على العزم، بينما كان لإجهاد خضوع الحديد تأثير ضعيفًا نسبيًا. يعتبر تحليل الحساسية ذات أهمية وذلك من خلال التركيز على المتغيرات الأكثر تأثيرًا عند تصميم الكمرات

وضبط المدخلات في الشبكة العصبية لضمان تنبؤ دقيق. كما يعكس التحليل أيضا قوة النموذج المعتمد على الشبكات العصبية، حيث يظل دقيقًا وموثوقًا عبر نطاق واسع من خصائص المواد وأبعاد المقطع، مما يؤكد صلاحيته كأداة للتنبؤ بالعزم في الكمرات الخرسانية. لدى فأن تحليل الحساسية يحدد المتغيرات الأكثر تأثيرًا، ويؤكد على ضمان قوة المعادلة في التنبؤ بالعزم الأقصى بدقة عالية.

جدول 4 تقييم تأثير متغيرات الإدخال على قيمة العزم المتوقع (MANN) للكمرات الخرسانية المسلحة.

التأثير على MANN	الحساسية (Sensitivity)	المتغير (Variable)
متوسط	3.53	عرض المقطع (b (mm)
عالي جدًا	7.69	العمق الفعال (d (mm)
عالي	.815	مساحة التسليح (A_s (mm ²)
منخفض	.361	مقاومة حديد التسليح (f_y (Mpa)
متوسط	2.87	مقاومة الخرسانة للضغط (f'_c (Mpa)

5. الخلاصة والتوصيات

تظهر نتائج الدراسة أن النموذج الرياضي المقترح من الشبكة العصبية الاصطناعية له قدرة ملحوظة على تمثيل السلوك غير الخطي للكمرات الخرسانية بدقة عالية مقارنة بالمعادلات التحليلية التقليدية المعقدة، الأمر الذي يعزز من إمكانية استخدامه في التطبيقات العملية في المراحل الأولية للتصميم الإنشائي. يُمثل تحليل الحساسية وسيلة فعالة لفهم سلوك النظام الإنشائي وتحديد العوامل الأكثر تأثيرًا. حيث تؤكد النتائج أهمية دراسة تأثير كل متغير بشكل مستقل ضمن إطار تحليل الحساسية، مثل أبعاد المقطع العرضي وخواص المواد ودورها المحوري في تحديد الاستجابة الإنشائية للكمرات. كما تشير نتائج الحساسية إلى وجود علاقات غير خطية معقدة بين المتغيرات المدروسة، مما يستدعي استخدام نماذج قادرة على استيعاب هذا السلوك. في المقابل، أثبت نموذج الشبكة العصبية المقترح قدرته على التقاط هذه العلاقات غير الخطية وتمثيلها بكفاءة عالية، بما يتوافق مع الأسس النظرية للهندسة الإنشائية. بشكل عام، يمكن القول إن النموذج المستخدم يحقق توازنًا مقبولًا بين البساطة وسهولة التطبيق من جهة، ودقة النتائج من جهة أخرى، مما يجعله مناسبًا للاستخدام في المراحل الأولية من التحليل والتصميم. ومع ذلك، تبقى دقة النتائج مرتبطة بحدود البيانات التي تم الاعتماد عليها، وهو ما يستدعي التوسع في الدراسات المستقبلية لتعزيز موثوقية النتائج وتوسيع نطاق تطبيقها.

بناءً على النتائج المتحصل عليها، يُوصى بالتوسع في استخدام نماذج الشبكات العصبية في تحليل وتصميم العناصر الإنشائية نظرًا لقدرتها على تمثيل العلاقات غير الخطية بدقة. كما يُنصح بإجراء دراسات مستقبلية تعتمد على قواعد بيانات أكبر وأكثر تنوعًا لتحسين دقة النماذج وزيادة موثوقيتها. بالإضافة إلى ذلك، يُستحسن دمج هذه النماذج مع الأساليب التقليدية في التحليل الإنشائي للحصول على نتائج أكثر شمولية ودقة.

6. المراجع

1. Bai, C., Nguyen, H., Asteris, P. G., Nguyen-Thoi, T., & Zhou, J. (2020). A refreshing view of soft computing models for predicting the deflection of reinforced concrete beams. *Engineering Structures*, 219, 110927.

2. Kaczmarek, M., & Szymańska, A. (2016). Application of artificial neural networks to predict the deflections of reinforced concrete beams. *Studia Geotechnica et Mechanica*, 38(3), 27-36.
3. Uziak, J., & Gandure, J. (2015). Comparative analysis of spreadsheet and MATLAB in beam bending calculations. University of Botswana, Gaborone, Botswana.
4. Kara, I. F., & Ashour, A. F. (2011). Flexural performance of FRP reinforced concrete beams. *Composite Structures*.
5. Ashraf, H. R., Jalal, M. & Garmsiri, K. (2010). Prediction of load-displacement curve of concrete reinforced by composite fibers (steel and polymeric) using artificial neural network. *Expert Systems with Applications*,
6. Ashour, A. F. & Habeeb, M. N. (2008). Continuous concrete beams reinforced with CFRP bars. *Proceedings of the Institution of Civil Engineers- Structures and Buildings*.
7. Muhammad I. M. Rjoub, Ph.D. (2005). *Moment Capacity of Steel Fiber Reinforced Concrete Beams*.
8. Ahmad, M. M., Elahi, A., & Barbhuiya, S. (2023). Comparative analysis of reinforced concrete beam behaviour: Conventional model vs. artificial neural network predictions. *Structures*, 54, 1895-1908.
9. Beljkaš, Ž. & Baša, N. (2021). Neural networks Deflection prediction of continuous beams with GFRP reinforcement. *Applied Sciences*, 11(14).