African Journal of Advanced Pure and Applied Sciences (AJAPAS)
Online ISSN: 2957-644X
Volume 5, Issue 4, 2026
Page No: 203-214
Website: https://aaasjournals.com/index.php/ajapas/index
ISI 2025: 1.126 SJIFactor 2024: 6.752 معامل التأثير العربي 2025: 1.65

Evaluation of Artificial Neural Network Performance in Classifying Anemia Cases Among Pregnant Women in Benghazi, Libya

Faiza Farag Elkhafifi [1 *], Nasr Wannees Almihdawi [2]
[1] Department of Statistics, Faculty of Science, University of Benghazi, Benghazi, Libya
[2] Ministry of Interior Headquarters, Benghazi, Libya

تقييم أداء الشبكات العصبية الاصطناعية في تصنيف حالات فقر الدم لدى النساء الحوامل في مدينة بنغازي

فائزة فرج الخفيفي [*1]، نصر ونيس المهدوي [2]
[1] قسم الاحصاء، كلية العلوم، جامعة بنغازي، بنغازي، ليبيا
[2] ديوان وزارة الداخلية، بنغازي، ليبيا

[*]Corresponding author: Faiza.farag@uob.edu.ly

Received: August 01, 2026	Accepted: October 13, 2026	Published: October 28, 2026

Abstract:
This study aimed to evaluate the ability of artificial neural networks (ANNs) to classify anemia cases among pregnant women, as anemia represents a major health challenge affecting the health of both mothers and fetuses. The study also sought to identify the most important variables associated with the classification process. The significance of this research lies in the potential use of modern classification methods to analyze health data and identify patterns and relationships among different variables. The study was based on secondary data collected from a sample of 600 pregnant women in Benghazi, Libya. The participants were randomly selected from several clinics and hospitals during the period 2020–2021, as reported in Nasr (2023). The dataset included a variety of demographic, health-related, and pregnancy-related variables. Anemia status was determined based on blood hemoglobin levels. Cases with hemoglobin levels below 11 (g/dL) were classified as anemic, whereas cases with levels of 11 (g/dL) or higher were classified as non-anemic, according to the criterion adopted in the study. Artificial neural networks were used to construct a classification model. The data were divided into two sets: a training set and a testing set, in order to evaluate the model's ability to classify cases correctly. The results showed that the classification accuracy reached 90.8% for the training data and 88.8% for the testing data. These findings indicate that the model achieved a good level of classification performance, with relatively similar results across the training and testing sets. The variable importance analysis also showed that bleeding during pregnancy ranked first, followed by nutritional supplements, iron tablet intake, previous miscarriage, weight, age, menstrual cycle duration, educational level, and gestational age in weeks. These findings highlight the potential of artificial neural networks for classifying health data and identifying the variables that contribute most to the classification process. The study recommends conducting further research using independent samples to assess the model's generalizability and utilizing classification results to support health research on anemia among pregnant women. It also emphasizes that the importance of variables within the model does not necessarily imply a causal relationship between those variables and the occurrence of anemia.

Keywords: Artificial Neural Networks, Anemia, Pregnant women, Classification, Input layer, Hidden layer, Output layer, Activation function.

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

الملخص:
هدفت هذه الدراسة إلى تقييم قدرة الشبكات العصبية الاصطناعية على تصنيف حالات فقر الدم لدى النساء الحوامل، باعتباره أحد أبرز التحديات الصحية العالمية التي تؤثر على صحة الأم والجنين، والتعرف على أهم المتغيرات المرتبطة بعملية التصنيف. وتنبع أهمية الدراسة من إمكانية الاستفادة من أساليب التصنيف الحديثة في تحليل البيانات الصحية والكشف عن الأنماط والعلاقات بين المتغيرات المختلفة. اعتمد البحث على بيانات ثانوية شملت 600 امرأة حامل من مدينة بنغازي، تم اختيارهن عشوائيًا من عدة عيادات ومستشفيات خلال فترة (2020-2021) (نصر، 2023). واشتملت البيانات على مجموعة متنوعة من العوامل الديموغرافية والصحية والمتعلقة بالحمل. وتم تحديد حالة فقر الدم بالاستناد إلى مستوى الهيموجلوبين في الدم، بحيث صُنفت الحالة التي يقل فيها مستوى الهيموجلوبين عن 11 (g/dL) ضمن فئة المصابات بفقر الدم، بينما صُنفت الحالات التي يبلغ فيها المستوى 11 (g/dL) أو أكثر ضمن فئة غير المصابات، وفق المعيار المعتمد في الدراسة. واستُخدمت الشبكات العصبية الاصطناعية لبناء نموذج تصنيفي، مع تقسيم البيانات إلى مجموعتين؛ إحداهما للتدريب والأخرى للاختبار، بهدف تقييم قدرة النموذج على تصنيف الحالات بصورة صحيحة. أظهرت النتائج أن دقة التصنيف بلغت 90.8% في بيانات التدريب، و88.8% في بيانات الاختبار، مما يشير إلى قدرة النموذج على تصنيف حالات فقر الدم لدى النساء الحوامل بدرجة جيدة، مع تقارب نسبي بين أدائه في مجموعتي التدريب والاختبار. كما بين تحليل أهمية المتغيرات أن النزيف أثناء الحمل جاء في المرتبة الأولى، تليه المكملات الغذائية، ثم تناول حبوب الحديد، والإجهاض السابق، والوزن، والعمر، ومدة الدورة الشهرية، والمستوى التعليمي، وعمر الجنين بالأسابيع. وتبرز هذه النتائج أهمية استخدام الشبكات العصبية الاصطناعية في تصنيف البيانات الصحية وتحديد المتغيرات الأكثر إسهامًا في عملية التصنيف. وتوصي الدراسة بإجراء دراسات إضافية على عينات مستقلة للتحقق من قدرة النموذج على التعميم، والاستفادة من نتائج التصنيف في دعم الدراسات الصحية المتعلقة بفقر الدم لدى النساء الحوامل، مع مراعاة أن أهمية المتغيرات في النموذج لا تعني بالضرورة وجود علاقة سببية بينها وبين الإصابة بفقر الدم.

الكلمات المفتاحية: الشبكات العصبية الاصطناعية، فقر الدم، النساء الحوامل، التصنيف، طبقة الإدخال، الطبقة الخفية، طبقة الإخراج، دالة التنشيط.

مقدمة

في هذا البحث سيتم استخدام نموذج تقنية الشبكات العصبية في تصنيف المشاهدات لمرض فقر الدم (الأنيميا)، حيث يعتمد مرض فقر الدم لدى نساء الحوامل ومقارنة مع نموذج اللوجستي هو من أخطر الامراض التي تصيب النساء الحوامل، ويعد فقر الدم من أكثر الاضطرابات الدموية انتشاراً في مختلف أنحاء العالم وخاصة في دول العالم الثالث (WHO, 2008).

الشبكات العصبية Artificial Neural Networks تُظهر قدرة قوية على تصنيف المشاهدات في مجالات متعددة، ويمكن تلخيص هذه القدرة في التعلم العميق تستخدم الشبكات العصبية العميقة بنية معقدة تتكون من عدة طبقات مما يسمح لها بالتقاط الأنماط الدقيقة والمعقدة في البيانات التعامل مع البيانات غير المهيكلة يمكن للشبكات العصبية معالجة أنواع مختلفة من البيانات مثل الصور، النصوص، والأصوات يمكن للشبكات العصبية تحسين أدائها بمرور الوقت مع زيادة البيانات المستخدمة في التدريب التعميم الجيد بعد التدريب على مجموعة من البيانات، يمكن للشبكات العصبية أن تعمم بشكل جيد على بيانات جديدة لم تُستخدم في التدريب، مما يزيد من دقتها في التصنيف.

مشكلة البحث Research Problem

تكمن مشكلة البحث في بناء نموذج إحصائي لمعرفة العوامل المؤثرة على فقر الدم لدى النساء الحوامل بواسطة الشبكات العصبية الاصطناعية و قدرتها على تصنيف المرض ويعتبر مرض فقر الدم (الأنيميا) من أخطر الأمراض التي تصيب النساء الحوامل، لأنه متعلق بالدم المسئول عن جميع الأنشطة الحيوية بالجسم، فجسم المرأة الحامل يحتاج إلى إمدادات ثابتة من الدم الغني بالأكسجين ليقوم بوظائفه بشكل سليم وتكمن الخطورة بالجهل بالعوامل المؤثرة على الإصابة، وعدم القدرة على تحديد العوامل التي تؤدي للإصابة بالمرض وتكمن المشكلة في معرفة أهم العوامل والأسباب للإصابة بفقر الدم للحمل وفي هذه الدراسة نقوم ببناء نموذج إحصائي لمعرفة العوامل المؤثرة على فقر الدم لدى النساء الحوامل.

أهمية البحث Significance of the Research

- الحاجة إلى استخدام أحد أساليب التصنيف الحديثة والتي لا تتطلب شروط معينة للاستخدام مثل أسلوب الشبكات الاصطناعية.
- دراسة أهم العوامل المؤثرة على الإصابة بفقر الدم لدى النساء الحوامل.

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

أهداف البحث Research Objectives

- التعرف على مفهوم الشبكات العصبية كأحد أساليب التصنيف.
- تحديد أهم العوامل المؤثرة على مرض فقر الدم (الأنيميا) لدى النساء الحوامل.

فرضيات البحث Hypotheses Of Research

1. الشبكات العصبية لها قدرة وكفاءة عالية في تصنيف البيانات .
2. المتغيرات التوضيحية تؤثر على المتغير التابع.
3. H_0: النموذج الإحصائي غير معنوي.

H_1: النموذج الإحصائي معنوي.

مصادر البيانات Data sources

يمثل مجتمع هذا البحث النساء الحوامل في مدينة بنغازي ونظرا لكبر حجم المجتمع تم أخذ عينة عشوائية بحجم 600 من النساء الحوامل المصابات بفقر الدم وعدم الإصابة بفقر الدم خلال فترة (2020-2021) (نصر، ندى مسعود، 2023).

الدراسات السابقة Literature Review

1. فقر الدم هو أكثر أمراض الدم شيوعًا في جميع أنحاء العالم، وتُعرّفه منظمة الصحة العالمية بأنه حالة يكون فيها عدد خلايا الدم الحمراء أو قدرة الجسم على حمل الأكسجين غير كافٍ وباعتباره مرضًا وعرضًا في آنٍ واحد فإن هذه الحالة تؤثر على جودة الحياة يُعد التشخيص المبكر والدقيق لنوع فقر الدم أمرًا بالغ الأهمية لعلاج المريض وقد يعيق تزايد عدد المرضى وأولويات المستشفيات بالإضافة إلى صعوبات الوصول إلى المتخصصين الطبيين، هذا التشخيص. يقترح هذا العمل نظامًا يُمكّن من التعرف على فقر الدم في ظل ظروف الممارسة السريرية العامة لهذا النظام تم بناء نموذج باستخدام أربع طرق مختلفة للتعلم الاصطناعي تُستخدم الشبكات العصبية الاصطناعية وآلات المتجهات الداعمة وخوارزمية بايز الساذجة وطرق شجرة القرار المجمعة كخوارزميات تصنيف يتم تقييم النماذج باستخدام مجموعة بيانات من 1663 عينة واستخدام 25 سمة، بما في ذلك بيانات مخطط الدم ومعلومات عامة مثل العمر والجنس والأمراض المزمنة والأعراض لتشخيص 12 نوعًا مختلفًا من فقر الدم. يتم جمع البيانات من خلال فحص ملفات المرضى في مستشفى جامعي في تركيا. بالإضافة إلى جميع البيانات التي استخدمها الأطباءاستخدم النموذج ثماني مجموعات بيانات مختلفة أُنشئت باستخدام تقنيات اختيار ميزات مُحددة. صُممت الواجهة لتوفير دعم اتخاذ القرار لكل من الاستشاريين الطبيين وطلاب الطب. تُصنف البيانات باستخدام أربع خوارزميات مختلفة ويتم الحصول على نسبة نجاح مقبولة لكل منها. يُتحقق من صحة كل نموذج باستخدام مقاييس خطأ التصنيف، والمساحة تحت المنحنى والدقة، والتذكير، ودرجة F بالإضافة إلى قيم الدقة. تم تحقيق أعلى دقة (85.6%) باستخدام أشجار القرار المُجمّعة، تليها الأشجار المُعززة (83.0%)، ثم الشبكات العصبية الاصطناعية (79.6%). (Yıldız,2021).

2. **Wu, K. et al. (2004)** :ركزت الدراسة على التنبؤ بنتائج الرعاية الصحية للأطفال منخفضي الوزن جدًا باستخدام الشبكات العصبية .جمعت بيانات من 500 حالة شملت معايير طبية كوزن الولادة والعمر الحملي . أظهرت الشبكة العصبية دقة تنبؤ بنسبة 90% في تحديد مضاعفات الرعاية، متفوقة على الانحدار اللوجستي (82%)أكدت الدراسة قدرة الشبكات العصبية على التقاط الأنماط غير الخطية بين المتغيرات الحيوية، مما يُمكّن الأطباء من اتخاذ قرارات علاجية أدق .كما ناقشت ضرورة تقديم تفسيرات مبسطة للنتائج الطبية الناتجة عن الشبكات العصبية، لتعزيز الثقة بين الكوادر الطبية في استخدامها.
3. **Polat, K. & Güneş, S. (2007)**: طورت هذه الدراسة أسلوبًا هجينًا باستخدام النظام المناعي الاصطناعي مع خوارزمية الجيران الأقرب لتشخيص سرطان الثدي .اعتمدت على بيانات Wisconsin واستخدمت 30 متغيرًا نسيجيًا .بلغ معدل الدقة97% متفوقًا على الشبكات العصبية التقليدية (95%) والانحدار اللوجستي (92%)أظهرت النتائج أن هذا النهج يحقق توازنًا جيدًا بين الدقة والسرعة خصوصًا عند دمج أساليب الذكاء الاصطناعي التكيفية مع تقنيات التصنيف الإحصائية .تناولت الدراسة أهمية تقنيات اختيار المتغيرات الأمثل وتحسين الأداء عبر ضبط عدد الجيران والخصائص المناعية المستخدمة.

الاطار النظري للبحث

الشبكات العصبية Neural Network

شهدت السنوات الأخيرة توسعًا كبيرًا في تطوير واستخدام الشبكات العصبية الاصطناعية التي تُعد من أهم فروع الذكاء الاصطناعي بتستند هذه النماذج إلى محاكاة مبسطة لعمل الجهاز العصبي البيولوجي، مما يتيح لها القدرة على معالجة البيانات والتعلم منها دون برمجة مباشرة *(Haykin, 2009)*

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

تشير الإحصاءات الحديثة إلى أن استخدام الشبكات العصبية ارتفع بنسبة تفوق 60٪ خلال العقد الماضي مـا يعكـس تحـولًا كبيرًا نحو الاعتماد على هذه النماذج في الأنظمة الذكية كما تُظهر دراسات مقارنة أن أداء هذه الشبكات يتجـاوز 85٪ فـي عدة مهام قياسية ما يجعلها خيارًا مفضلًا في تطبيقات تحليل البيانات(*Zhang et al., 2020*) .
تعتمد الشبكات العصبية على بنية طبقية تتكون من وحدات تُعـرف بالعُقد(Neurons) تنتقـل الإشـارات بينهـا وفـق أوزان قابلة للتعديل ويتم تحسين هذه الأوزان عبر عملية تدريب تعتمد على خوارزمية الانحـدار العكسـي، التـي تهـدف إلـى تقليـل الخطأ بين المخرجات الفعلية والمتوقعة للنموذج (*Haykin, 2009*) .

حجر الأساس: العصبية (Neurons)

الوحدة الأساسية للشبكات العصبية (Neural Network)عرف باسم (Neurons)ومهمتها هـي أن تأخـذ بعـض المدخلات وتجري عليها عدة عمليات حسابية وتنتج لنا نتيجة أو مخرج.

طريقة عمل الشبكات العصبية How Neural Networks Work

الدماغ البشري هو مصدر الإلهام لهندسة الشبكات العصبية، تشكل خلايا الدماغ البشري التي يطلق عليها العصـبية، شـبكة معقدة ومترابطة للغاية وترسل إشارات كهربائية إلى بعضـها لمسـاعدة البشـر علـى معالجـة المعلومـات. علـى نحـو مماثـل تتكون الشبكات العصبية الاصطناعية من العصبية اصطناعية تعمل معًا لحل مشكلة ما. العصبية الاصطناعية هي وحـدات برمجية تطلق عليها العقد بينما تعرف الشبكات العصبية الاصطناعية بوصفها برامج برمجية أو لوغاريتمات تستخدم بشكل أساسي أنظمة حوسبة لحل العمليات الحسابية.

هندسة الشبكات العصبية البسيطة Simple neural network architecture

تتكون الشبكات العصبية الأساسية من عصبونات اصطناعية مترابطة في ثلاث طبقات:

متغيرات التوضيحية

- طبقة الإدخال Input layer

تدخل المعلومات من العالم الخارجي إلى الشبكات العصبية الاصطناعية عبر طبقة الإدخال تعالج عقد الإدخال البيانات أو تحللها أو تصنفها وتمررها إلى الطبقة التالية.

متغيرات الكاملة:

- الطبقة الخفية Hidden layer

تأخـذ الطبقـات الخفيـة مـدخلاتها مـن طبقـة الإدخـال أو الطبقـات الخفيـة الأخـرى يمكـن أن تتضـمن الشـبكات العصـبية الاصطناعية عددًا كبيرًا من الطبقات الخفية. تحلل كـل طبقـة خفيـة المخرجـات مـن الطبقـة السـابقة وتعالجهـا بشـكل أكبـر وتمررها إلى الطبقة التالية.

- طبقة الإخراج Output layer

تعطي طبقة الإخراج النتيجة النهائية لجميع عمليات معالجة البيانات التـي أجرتهـا الشـبكات العصـبونية الاصـطناعية. وقـد تتضمن عقدًا فردية أو متعـددة، علـى سـبيل المثـال: إذا كانـت لـدينا مشـكلة تصـنيف ثنـائي بــ (نعـم/ لا)، فستتضـمن طبقـة الإخراج عقدة إخراج واحدة تعطي النتيجة 1 أو 0. على الرغم من ذلك، إذا كانت لـدينا مشـكلة تصـنيف متعـدد الفئـات فقـد تتألف طبقة الإخراج من أكثر من عقدة إخراج واحدة.

التحليل الاحصائي و منهجية البحث

وصف المتغيرات

العدد الكلـي للمتغيـرات الداخلـة فـي هـذه الدراسـة هـو 10 متغيـر، منهـا متغيـرات نوعيـة ومتغيـرات كميـة وأيضـا المتغيرات النوعية ثم تصنيفها على أساس المتغير الوهمي (1)و(0)، حيث 1 تمثل ظهور الظاهرة و(0) تمثل عـدم ظهـور الظاهرة . تشمل عينة الدراسة (10) متغير، كما هو موضح في الجدول رقم (1)

جدول (1) متغيرات الدراسة

المتغير	رمز المتغير	نوع المتغير
مقدر الهيموجلوبين في الدم	y	كمي
العمر	x_1	كمي
الوزن	x_2	كمي
المستوى التعليمي	x_3	وصفي
يوجد اجهاض سابق	x_4	وصفي
عمر الجنين بالأسابيع	x_5	وصفي

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

المتغير	رمز المتغير	نوع المتغير
مدة الدورة الشهرية	x_6	وصفي
نزيف اثناء الحمل	x_7	وصفي
اخذ حبوب الحديد	x_8	وصفي
اخذ مكملات غذائية	x_9	وصفي

المتغير التابع في هذا البحث هو:

مقدار هيموجلوبين الدم HGB-g/d (y) متغير كمي وتم تحويله إلى متغير وصفي ليتلاءم مع هدف الدراسة 1 تمثل مقدار الهيموجلوبين في الدم أقل من 11 وهذا يعني أن المرأة الحامل لديها فقر دم (أنيميا). و مقدار الهيموجلوبين في الدم من 11، وأكثر وهذا يعني أن المرأة الحامل لا تعاني من فقر دم (أنيميا) تبعا لتصنيف منظمة الصحة العالمية 2011 WHO والجدول.2 يوضح توزيع مقدار هيموجلوبين الدم لدى النساء الحوامل في عينة الدراسة.

جدول (2) توزيع عينة الدراسة تبعا لمقدار الهيموجلوبين الدم

مقدار هيموجلوبين في الدم	العدد	النسبة
اقل من 11(تعاني من الانيميا)	**292**	**48.6%**
11 او اكثر (لا تعاني من الانيميا)	**308**	**51.4%**

نلاحظ من الجدول أعلاه أن 48.6% من النساء الحوامل في عينة الدراسة تعاني من الأنيميا و51.4% من عينة الدراسة لا تعاني من الأنيميا.

نتائج تحليل الشبكات العصبية Neural Network Analysis Results

تم استخدام الشبكات العصبية (Neural networks) وهي إدخال جميع المتغيرات المستقلة مرة واحدة ككل في النموذج و المعرفة من أهم المتغيرات المعنوية المؤثرة في المتغير التابع لدراستنا وهو مقدار هيموجلوبين الدم للمرأة الحامل حيث يأخذ القيمتين (1 وجود انيميا 0 عدم وجود أنيميا) والمتغيرات المستقلة هي العمر، الوزن ، المستوى التعليمي، يوجد اجهاض سابق عمر الجنين بالأسابيع، مدة الدورة الشهرية، نزيف أثناء الحمل، أخذ حبوب الحديد، أخذ مكملات غذائية، والجداول التالية توضح نتائج الشبكات

جدول (3) العينة الدراسة المختارة للتدريب

ملخص معالجة للمشاهدات			
		العدد	النسبة
عينة	التدريب	403	67.2%
	الاختبار	197	32.8%
	العدد	600	100.0%
	القيمة المستبعدة	0	
	المجموعة	600	

من الجدول السابق تم استخدام الشبكة العصبية للبيانات المتاحة بنسبة 67.2% من المشاهدات التي تدخل في عينة التدريب دون أية شروط. كما تم استخدام 32.8% المشاهدات الداخلة في عينة الاختبار بشكل تلقائي. وقد كان إجمالي بيانات البحث (600) مشاهدة تم إخضاعها جميعا للتحليل (التدريب والاختبار) ولم يستثنى أي مفردة .

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

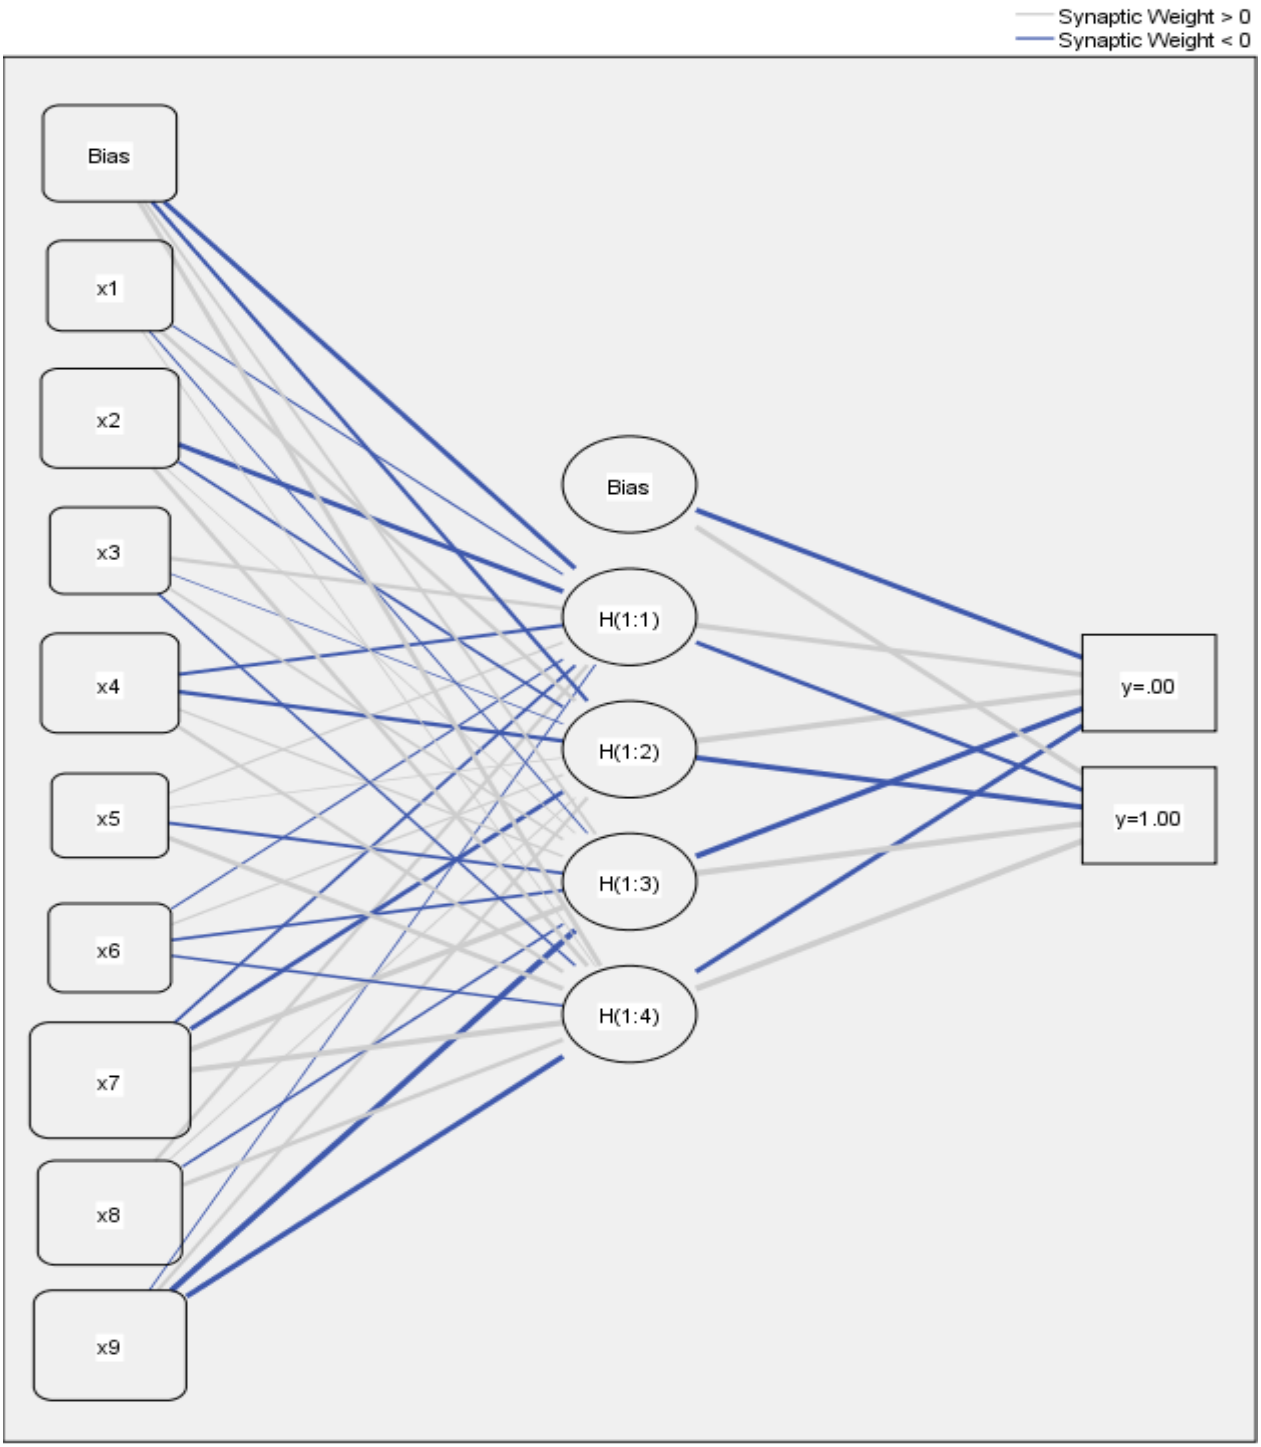
جدول (4) المعلومات الشبكية العصبية عدد الخلايا العصبية في كل طبقة

المعلومات الشبكية العصبية			
العمر	1	التغيرات	**ادخال الطبقة**
الوزن	2		
مستوى التعليمي	3		
يوجد اجهاض سابق	4		
عمر الجنين بالأسابيع	5		
مدة الدورة الشهرية	6		
نزيف اثناء الحمل	7		
اخد حبوب الحديد	8		
اخد مكملات الغذائية	9		
9		عدد الوحدات	
المعيارية		طريقة إعادة القياس للمتغيرات المشتركة	
1		عدد الطبقات المخفية	**الطبقة المخفية(s)**
4		عدد الوحدات في الطبقة المخفية	
المماس الزائدي		الدالة النشطة	
هيموجلوبين الدم	1	المتغير التابع	**الطبقة المخرجة**
2		عدد الوحدات	
max Soft		الدالة النشطة	
Cross-entropy		دالة الخطأ	

يوضح الجدول (4) نلاحظ أن عدد الخلايا العصبية في كل طبقة، نجد أن طبقة المدخلات (Input Layer) تمثل إجمالي المتغيرات الداخلة في البحث وعددها (تسع متغيرات مستقلة) بالإضافة إلى الخطأ (طبقة التحيزBias) وقد اعتمد في حسابها على طريقة Standardized.

الطبقة المخفية ((Hidden Layer(S):تمثل **الطبقة** التي تقع بين طبقتي المدخلات والمخرجات ونجد أنها في هذا البحث تمثلت في طبقة مخفية **واحدة** موصولة اربع وحدات بالإضافة إلى الخطأ Bias طبقة التحيز وقد تم اختيار هذه الطبقة بالاعتماد على البرنامج حيث انه يختار أفضل عدد من الخلايا العصبية لنموذج الشبكة عن طريق المحاولة والخطأ ودالة التنشيط المستخدمة هي دالة القطعHyperbolic tangent. أما طبقة المخرجاتOutput Layer تمثل المتغير التابع (الهيموجلوبين في الدم) ويتكون من طبقتين (يوجد انيميا ، لا توجد انيميا) ، بدالة التنشيط المستخدمة Soft max

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).



الشكل 1: هيكلية الشبكة العصبية

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

جدول (5) ملخص نموذج الشبكات العصبية

ملخص النموذج		
التدريب	خطأ التداخل	92.842
	نسبة التوقعات الخطأ	9.2%
	استخدام قاعدة الايقاف	1 consecutive step(s) with no decrease in error
	زمن التدريب	0:00:00.07
الاختبار	خطأ التداخل	56.795
	نسبة التوقعات الخطأ	11.2%
المتغير التابع		

من جدول (5) نلاحظ أن مجموع مربعات الأخطاء لعينة التدريب (92.842) بنسبة التوقع الخاطئة (9.2 %) وقد استغرقت الشبكة (0:00:00:07 جزء من الثانية) للتدريب وهو زمن صغير جدا والذي يعني أن الشبكة العصبية تستطيع التعامل مع مثل هذه النماذج بشكل سريع وقوي أما مجموع مربعات الأخطاء لعينة الاختبار (56.795) نسبة التوقع الخاطئة (11.2%) وهي أكبر من نسبة التوقع الخاطئة لنموذج التدريب. تعتبر هذه النسبة صغيرة مما يدلل على أن الشبكة تدربت بشكل ممتاز على تصنيف المفردات الجديدة في النموذج.

جدول (6) التصنيف

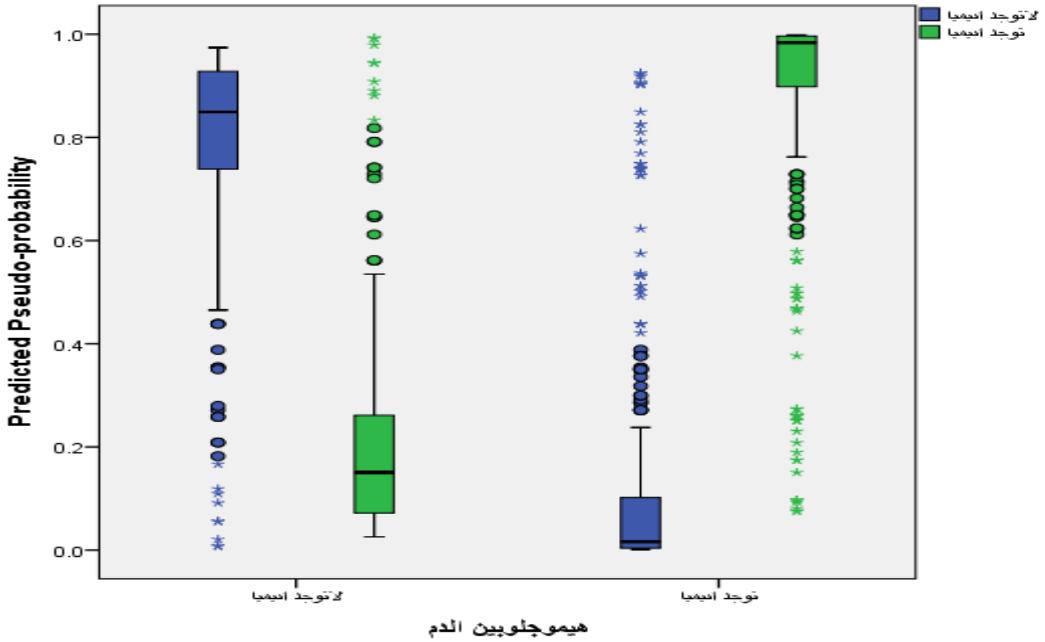
التصنيف				
عينة	المشاهدات	المتوقع		
		لا توجد انيميا	توجد انيميا	النسبة الصحيحة
التدريب	لا توجد انيميا	117	17	87.3%
	توجد انيميا	20	249	92.6%
	مجموع النسبة	34.0%	66.0%	90.8%
اختبار	لا توجد انيميا	61	8	88.4%
	توجد انيميا	14	114	%89.1
	مجموع النسبة	38.1%	61.9%	88.8%
المتغير التابع هيموجلوبين الدم				

من جدول رقم (6) يبين ان كفاءة التصنيف نجد أن نسبة التصنيف الصحيح، لفئة (لا توجد انيميا)، في عينة التدريب هي (87.3%) وفي عينة الاختبار بلغت نسبة التصنيف الصحيح (88.4%) وكانت أكبر نسبة في عينة التدريب يمكن الحصول عليها في نموذج الشبكات العصبية.

أما فئة (توجد انيميا) فقد بلغت نسبة التصنيف الصحيح في عينة التدريب (92.6%) وفي عينة الاختبار (89.1%) وهي نسبة عالية.

كما نجد أن نسبة التصنيف الصحيح الكلي للنموذج الخاص عينة التدريب بلغت (90.8%) ونسبة التصنيف الصحيح الكلي للنموذج الخاص عينة الاختبار بلغت (88.8%)، وهي نتيجة ممتازة تدل على أن الشبكة تدربت بشكل جيد مع مفردات العينة.

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

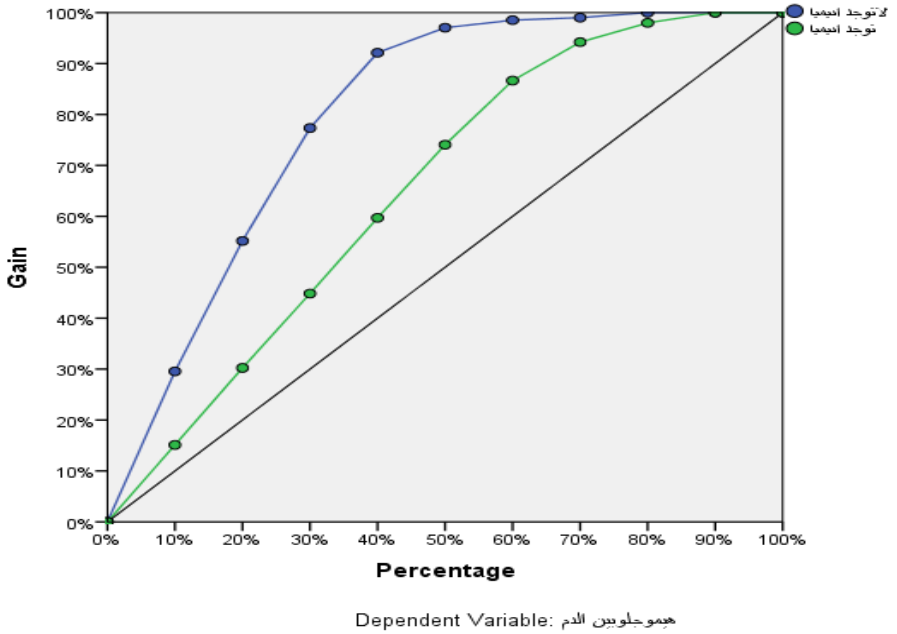


الشكل 2: مخطط الاحتمالية الزائفة المتوقعة
Pseudo-likelihood plot

مخطط الاحتمالية الزائفة المتوقعة Predicted Pseudo-probability هو نوع من الرسومات، التي تستخدم في تحليل نتائج النماذج العصبية وتظهر كيفية توزيع الاحتمالات التي يتنبأ بها النموذج لمختلف الفئات، والذي تظهر فيه التنبؤات الصحيحة للقيم الأعلى من (0.05) وهذا الشكل سنفصله كما يلي:

الجهة اليمنى: يظهر المخطط الصندوق الاخضر (bloxplot)التصنيف الصحيح لفئة (توجد انيميا) (أي المشاركين كانت المتوقع إجابتهم توجد انيميا وبالفعل كانت إجابتهم توجد انيميا والصندوق الأزرق يظهر التصنيف الغير صحيح.

الجهة اليسرى: يظهر المخطط الصندوق الأزرق (bloxplot)التصنيف الصحيح لفئة (لا توجد انيميا) والصندوق الأحمر يظهر التصنيف الغير صحيح.



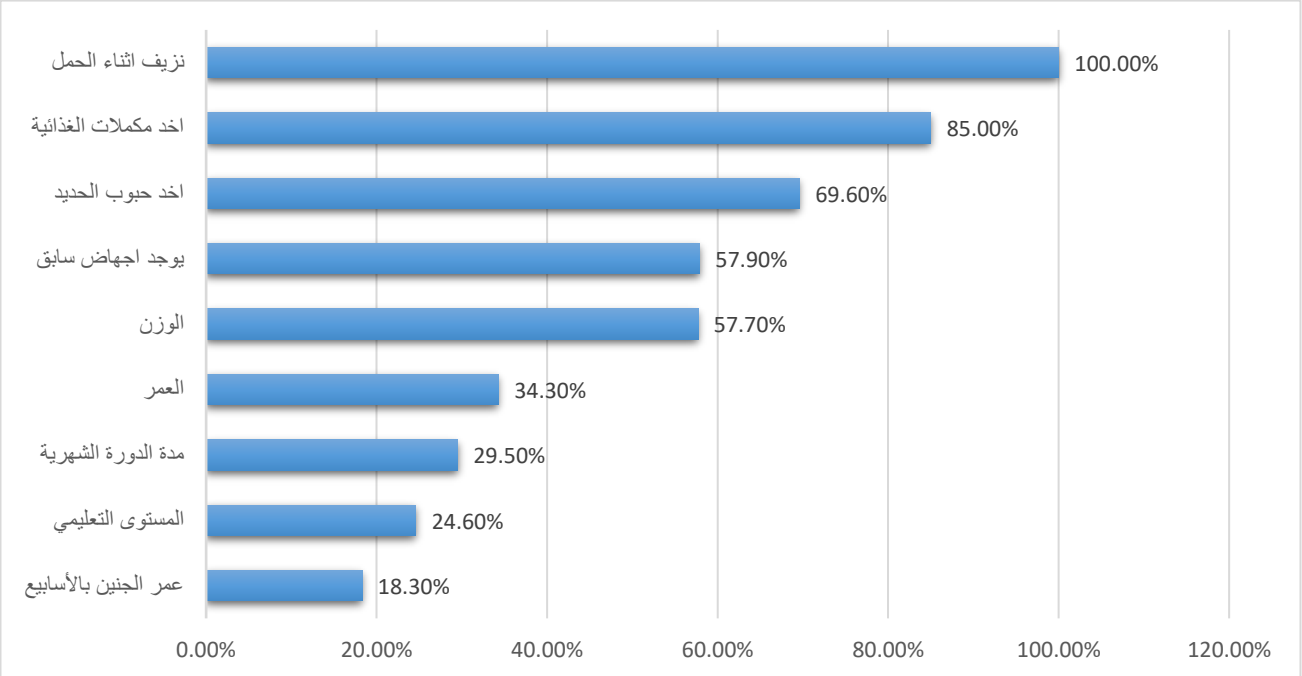
الشكل 3: مخطط العائد التجميعي (Cumulative Gain Chart)

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

الشكل (3) مخطط العائد التجميعي Cumulative Gain يعرض نسبة العدد الإجمالي، للحالات التي كسبتها الفئة الواحدة، من خلال استهداف نسبة العدد الإجمالي للحالات ونلاحظ من المخطط أن النقطة الأولى لمنحنى الفئة ذات اللون الازرق، تقع في الإحداثيات من (30%,10%) وهذا يعني أن التوقع أعلى من (10%) من الحالات التي تحتوي على ما يقارب 30% من الحالات التي تأخذ فئة (لا توجد انيميا) وبالمثل فان (20%) من الحالات تحتوي على ما يقارب (60%) وهكذا حتى الوصل إلى نسبة (100%) الحالات. كما نلاحظ من المخطط أن النقطة الثانية لمنحنى الفئة ذات اللون الاخضر تقع في الإحداثيات من (10%، 15%) وهذا يعني أن التوقع أعلى من (10%) من الحالات التي تحتوي على ما يقارب (30%) من الحالات التي تأخذ فئة (توجد انيميا) وبالمثل فان (20%) من الحالات تحتوي على ما يقارب (30%) وهكذا حتى الوصول إلى نسبة (100%) من الحالات. وبما أن كامل النقاط أعلى من منحنى خط الأساس فالشبكة جيدة للتنبؤ لحالات التنبؤ مساهمة لا توجد انيميا وتوجد انيميا.

جدول (7) أهمية المتغيرات المستقلة في نموذج الشبكات العصبية

أهمية المتغيرات المستقلة		
	أهمية	الأهمية المعيارية
نزيف اثناء الحمل	0.210	100.0%
اخذ مكملات الغذائية	0.178	85.0%
اخذ حبوب الحديد	0.146	69.6%
يوجد اجهاض سابق	0.121	57.9%
الوزن	0. 121	57.7%
العمر	0.072	34.3%
مدة الدورة الشهرية	0.062	29.5%
المستوى التعليمي	0.052	24.6%
عمر الجنين بالأسابيع	0.038	18.3%



الشكل 4: الأهمية النسبية

يتضح من الجدول والشكل السابق أن متغير النزيف أثناء الحمل أكبر درجة أهمية حيث بلغت نسبة أهميته (100%) مما يعني أنه يلعب دورا حاسما في توقع النتيجة ثم يليه متغير يليه متغير تناول المكملات الغذائية بنسبة 85.0% ثم تناول حبوب الحديد بنسبة 69.6% ثم جاء في المرتبة الرابعة وجود إجهاض سابق بنسبة 57.9% ثم جاء في المرتبة الخامسة متغير الوزن بنسبة 57.7%. أما المتغيرات الأخرى فقد تراوحت أهميتها المعيارية بين 18.3% و34.3%.

وتشير هذه النتائج إلى اختلاف الأهمية النسبية للمتغيرات في عملية التصنيف وفق النموذج المستخدم ولا ينبغي تفسير هذه القيم بوصفها مقاييس مباشرة للتأثير السببي بل بوصفها مؤشرات على الأهمية النسبية للمتغيرات داخل النموذج.

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

نتائج الدراسة

بناءً على التحليل الإحصائي والتطبيقي لنموذج الشبكات العصبية الاصطناعية (ANN)على عينة الدراسة المكونة من 600 امرأة حامل، أسفرت الدراسة عن النتائج الرئيسية التالية:

1. **معدل انتشار أنيميا الحمل:** أظهرت النتائج الوصفية أن نسبة الإصابة بفقر الدم (أنيميا الحمل) بلغت **48.6%** (n = 292) من إجمالي عينة الدراسة، بينما بلغت نسبة غير المصابات **51.4%** (n = 308).
2. **كفاءة معمارية الشبكة العصبية:** تم الوصول إلى بناء شبكي كفء يتكون من:
   - **طبقة إدخال (Input Layer):** تتضمن 9 متغيرات مستقلة بالإضافة إلى وحدة التحيز (Bias).
   - **طبقة مخفية واحدة (Hidden Layer):** تحتوي على 4 وحدات مع دالة تنشيط المماس الزائدي (*Hyperbolic Tangent*).
   - **طبقة مخرجات (Output Layer)** تعتمد على دالة *Softmax* مع دالة أخطاء التداخل (*Cross-Entropy*).
   - **سرعة فائقة في التدريب:** تم تدريب النموذج في زمن قياسي قدره **0.07 ثانية**، مع نسبة توقع خاطئ منخفضة بلغت 9.2% لعينة التدريب و11.2% لعينة الاختبار.
3. **قدرة تصنيفية عالية (Accuracy):**
   - حقق النموذج نسبة تصنيف صحيح إجمالية بلغت **90.8%** لعينة التدريب (n = 403) و**88.8%** لعينة الاختبار (n = 197).
   - تميز النموذج بكفاءة تصنيفية عالية جداً في الكشف عن الحالات المصابة بالأنيميا تحديداً، حيث بلغت نسبة التصنيف الصحيح لفئة "توجد أنيميا" **92.6%** في عينة التدريب و**89.1%** في عينة الاختبار.
4. **الأهمية المعيارية للمتغيرات (Normalized Importance):**

أظهر تحليل الأهمية النسبية للمتغيرات المستقلة المؤثرة في التنبؤ بمستوى هيموجلوبين الدم الترتيب التالي:

- **المرتبة الأولى:** متغير **"النزيف أثناء الحمل"** بأهمية معيارية مطلقة بلغت **100.0%** (وزن أهمية 0.210)، مما يجعله المتغير الحاسم الأكثر تأثيراً.
- **المرتبة الثانية:** متغير **"أخذ مكملات غذائية"** بنسبة أهمية معيارية **85.0%** (وزن 0.178).
- **المرتبة الثالثة:** متغير **"أخذ حبوب الحديد"** بنسبة أهمية معيارية **69.6%** (وزن 0.146).
- **المرتبة الرابعة:** متغير **"يوجد إجهاض سابق"** بنسبة أهمية معيارية **57.9%** (وزن 0.121).
- **المرتبة الخامسة:** متغير **"الوزن"** بنسبة أهمية معيارية **57.7%** (وزن 0.121).
- **المراتب المتأخرة:** جاء متغير "العمر" (34.3%)، "مدة الدورة الشهرية" (29.5%)، "المستوى التعليمي" (24.6%)، وأخيراً "عمر الجنين بالأسابيع" (18.3%).

التوصيات

في ضوء النتائج التي تم التوصل إليها، يُوصى بالآتي:

1. **الإنذار المبكر والرعاية المباشرة:**
   - التركيز الصارم في مراكز الرعاية الصحية الأولية على النساء اللاتي يعانين من **نزيف أثناء الحمل** باعتباره المسبب والمؤشر الأكبر خطورة للإصابة بأنيميا الحمل (بأهمية 100%).
2. **تعزيز البرامج الغذائية والدوائية:**
   - تفعيل برامج إجبارية لمتابعة تناول **المكملات الغذائية وحبوب الحديد** للحوامل منذ الأشهر الأولى، نظرًا لدورهما المباشر والكبير في الوقاية من هبوط هيموجلوبين الدم.
3. **المتابعة الخاصة للحالات ذات التاريخ الطبي الحرج:**
   - إيلاء عناية طبية مكثفة للنساء اللاتي لديهن تاريخ في **الإجهاض السابق** ومتابعة أوزانهن بشكل دوري أثناء فترة الحمل.
4. **اعتماد الذكاء الاصطناعي في المنظومة الصحية:**
   - الدفع نحو استخدام خوارزميات **الشبكات العصبية الاصطناعية (ANN)** في المستشفيات والمراكز الصحية للتشخيص والتنبؤ المبكر بأنيميا الحمل، نظراً لسرعتها الفائقة ودقتها العالية التي تتجاوز 90% دون الحاجة لافتراضات إحصائية معقدة.

Compliance with ethical standards

Disclosure of conflict of interest

The authors declare that they have no conflict of interest.

 Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).

قائمة المراجع (References)

أولا المراجع العربية

[1] نصر، ندى مسعود. (2023). *العوامل المؤثرة على فقر الدم لدى النساء الحوامل في مدينة بنغازي باستخدام أساليب التحليل الإحصائي* [رسالة ماجستير غير منتشرة]. جامعة بنغازي.

[2] المغربي و الخفيفي. (2023)استخدام أسلوب الانحدار اللوجستي الثنائي في دراسة ميدانية عن فقر الدم لدى النساء الحوامل في مدينة بنغازي. المجلة الليبية العالمية.العدد 68-ليبيا

ثانيا المراجع الاجنبية

[1] Haykin, S. "*Neural networks and learning machines* " (3rd ed.). Pearson Education(2009)..

[2] Polat, K., & Güneş, S.. "Breast cancer diagnosis using a hybrid system based on Artificial Immune System and$ k$-nearest neighbor algorithm". *Neurocomputing* ,(2007). .2789–2782 ,(18–16)*70* https://doi.org/10.1016/j.neucom.2006.05.023

[3] World Health Organization. " *Worldwide prevalence of anaemia 1993–2005: WHO global database on anaemia* "B. de Benoist, E. McLean, I. Egli, & M. Cogswell, Eds.). (2008). World Health Organization. https://apps.who.int/iris/handle/10665/43894

[4] World Health Organization. " *Haemoglobin concentrations for the diagnosis of anaemia and assessment of severity* (Vitamin and Mineral Nutrition Information System", WHO/NMH/NHD/MNM/11.1). World Health Organization(2011). https://apps.who.int/iris/handle/10665/85839

[5] Wu, K., Chen, X., & Zhang, Y. "Predicting healthcare outcomes in very low birth weight infants using artificial neural networks". *Journal of Medical Systems*(2004). .427–415 ,(4)*28* , https://doi.org/10.1023/B:JOMS.0000033662.62892.d6

[6] Yıldız, M. " Anemia diagnosis system using machine learning algorithms". *Medical & Biological Engineering & Computing* ,(2021) .1448– 1435 ,(7)*59* https://doi.org/10.1007/s11517-021-02388-3

[7] Zhang, L., Tan, J., Han, D., & Zhu, H. "From machine learning to deep learning".A review of methods and applications in medical data analysis. *Computers in Biology and Medicine* ,(2020). 104014 ,*125* https://doi.org/10.1016/j.compbiomed.2020.104014

Disclaimer/Publisher's Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of **AJAPAS** and/or the editor(s). **AJAPAS** and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.

Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (https://creativecommons.org/licenses/by/4.0/).