

Flood Modeling Using Artificial Intelligence and Machine Learning Techniques (North Kabir River Case Study in Syria)

Jomana Eskandar* 

Dr. Shaaban Hadeed**

Dr. Elias Layous***

(Received 7 / 4 / 2025. Accepted 12 / 8 / 2025)

□ ABSTRACT □

The North Kabir River Basin has been subjected to frequent floods that have led to environmental, social, and economic disasters in the region. This research aims to identify important factors in flood risk management, in the context of accelerated climate change. The Geographic Information System (GIS) was used to analyze spatial data related to floods, where Machine Learning techniques, which are part of Artificial Intelligence, were integrated to analyze these data and extract patterns and predictions, through the AutoML environment available in ArcGIS Pro, which allows for optimal model selection and automatic parameter tuning (parameter optimization), and using a set of machine learning algorithms including: Linear regression, decision tree, random trees, absolute gradient enhancement, light gradient enhancement, and additional trees, and the analysis relied on sixteen environmental and geographical parameters that represent the most important factors contributing to the generation of floods, namely: Elevation, steepness, linear surface curvature, runoff accumulation, slope length, slope-length factor, length-slope factor, rainfall amount, topographic moisture index, terrain ruggedness index, terrain condition index, current strength index, drainage network density, distance from riverbeds, Normalized Difference Vegetation Index, and land use and coverage, and the performance of the different models was evaluated using multiple accuracy measures such as sensitivity, recall, and F1 score. The results showed the superiority of the linear regression model in recognizing patterns associated with flood risk, while the resulting maps showed that high-risk areas are concentrated in the south and southwest of the basin, while low-risk areas are distributed in the north and northeast. This study reflects the importance of employing advanced scientific methods to analyze floods, contributing to the promotion of sustainable water resources management strategies.

Keywords: Artificial Intelligence, Artificial Intelligence, Machine Learning, Geographic Information Systems (GIS), Flood Forecasting.

Copyright



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

* Postgraduate student (Ph.D.), Department of Water Resources Engineering and Management, Faculty of Civil Engineering, Homs University, Homs, Syria. Jomeaska777@gmail.com

** Professor, Department of Water Resources Engineering and Management, Faculty of Civil Engineering, Homs University, Homs, Syria.

***Professor, Department of Water Resources Engineering and Management, Faculty of Civil Engineering, Homs University, Homs, Syria.

نمذجة الفيضانات باستخدام تقانات الذكاء الاصطناعي تعلم الآلة (حالة دراسة نهر الكبير الشمالي في سورية)

جمانة خضر اسكندر* 

الدكتور شعبان حديد**

الدكتور الياس ليوس***

(تاريخ الإيداع 2025 / 4 / 7. قَبْلَ للنشر في 2025 / 8 / 12)

□ ملخص □

تعرض حوض نهر الكبير الشمالي لفيضانات متكررة أدت إلى كوارث بيئية، واجتماعية، واقتصادية في المنطقة. يهدف هذا البحث إلى تحديد العوامل المهمة في إدارة مخاطر الفيضانات، في سياق التغيرات المناخية المتسارعة. تم استخدام نظام المعلومات الجغرافية (GIS) لتحليل البيانات المكانية المتعلقة بالفيضانات، حيث تم دمج تقانات التعلم الآلي (Machine Learning)، التي تعد جزءاً من الذكاء الاصطناعي، لتحليل هذه البيانات واستخراج الأنماط والتوقعات، وذلك من خلال بيئة AutoML المتوفرة في برنامج ArcGIS Pro، التي تتيح اختيار النموذج الأمثل وضبط المعاملات تلقائياً (تحسين المعاملات)، واستخدام مجموعة من خوارزميات التعلم الآلي شملت: الانحدار الخطي، شجرة القرار، الأشجار العشوائية، تعزيز التدرج المطلق، تعزيز التدرج الخفيف، والأشجار الإضافية، واعتمد التحليل على مجموعة معايير مهمة مثل الارتفاع، شدة الانحدار، انحناء السطح، تراكم الجريان السطحي، عامل الطول-الانحدار، كمية الهطول المطري، مؤشر الرطوبة الطبوغرافي، مؤشر وعورة التضاريس، مؤشر الوضع التضاريسي، مؤشر طاقة الجريان، كثافة المسيلات المائية، المسافة عن المسيلات المائية والطرق، مؤشر الغطاء النباتي، واستخدامات الأراضي، والليتولوجيا وتم تقييم أداء النماذج المختلفة باستخدام مقاييس دقة متعددة مثل الحساسية والاسترجاع ودرجة F1. أظهرت النتائج تفوق نموذج الانحدار الخطي في التعرف على الأنماط المرتبطة بمخاطر الفيضانات، في حين بيّنت الخرائط الناتجة أن المناطق عالية الخطورة تتركز في الجنوب والجنوب الغربي من الحوض، بينما تتوزع المناطق الأقل خطورة في الشمال والشمال الشرقي. تعكس هذه الدراسة أهمية توظيف الأساليب العلمية المتقدمة لتحليل الفيضانات، بما يسهم في تعزيز استراتيجيات الإدارة المستدامة للموارد المائية.

الكلمات المفتاحية: نهر الكبير الشمالي، الذكاء الاصطناعي، التعلم الآلي، نظم المعلومات الجغرافية، التنبؤ بالفيضانات.



حقوق النشر : مجلة جامعة اللاذقية (تشرين سابقاً) - سورية، يحتفظ المؤلفون بحقوق النشر بموجب

الترخيص CC BY-NC-SA 04

* طالبة دراسات عليا (دكتوراه) - قسم هندسة وإدارة الموارد المائية - كلية الهندسة المدنية - جامعة حمص - حمص - سورية .

Jomeaska777@gmail.com

** أستاذ - قسم هندسة وإدارة الموارد المائية - كلية الهندسة المدنية - جامعة حمص - حمص - سورية.

*** أستاذ - قسم هندسة وإدارة الموارد المائية - كلية الهندسة المدنية - جامعة حمص - حمص - سورية.

مقدمة:

يعد النهر الكبير الشمالي أحد الأنهار الرئيسية في سورية، وينبع من الجبال الغربية في سورية ويجري في اتجاه الشمال الغربي قبل أن يصل إلى لبنان ويصب في خليج عسیر، ويتميز بتنوع بيئته وأهميته المائية، ولكنه يواجه تحديات تتعلق بالفيضانات [1]. تاريخياً يتعرض النهر للفيضانات المفاجئة، خاصة خلال فصل الشتاء عندما تتساقط الأمطار بغزارة. تؤدي هذه الفيضانات إلى تأثيرات سلبية على البيئة المحلية والمجتمعات المحيطة، بما في ذلك فقدان المحاصيل وتدمير البنية التحتية. كما أن هناك عوامل بشرية، مثل تغير استخدام الأراضي والتوسع العمراني، التي تزيد من حدة الفيضانات [2]. تشير الدراسات إلى أن إدارة المياه والتحكم في الفيضانات في حوض النهر الكبير الشمالي تتطلب استراتيجيات شاملة، تشمل تحسين شبكات الصرف وإعادة تقييم استخدامات الأراضي. تعد الفيضانات من الكوارث الطبيعية التي لها تأثيرات طويلة الأمد على الاقتصاد والمجتمع.

يعد الذكاء الاصطناعي (Artificial Intelligence) أحد أكثر الابتكارات التكنولوجية تقدماً وتأثيراً في العصر الحديث، حيث يُعنى بتطوير أنظمة تُحاكي العمليات الذهنية البشرية مثل التعلم، التحليل، واتخاذ القرار، ويعد "تعليم الآلة" (Machine Learning) فرعاً أساسياً من الذكاء الاصطناعي، يعتمد على خوارزميات تمكّن الأنظمة من التعلم من البيانات وتحسين أدائها دون تدخل بشري مباشر [3]. من خلال معالجة كميات كبيرة من البيانات، تسهم نماذج تعلم الآلة في استخراج الأنماط والتوجهات التي قد تكون غير مرئية للعين البشرية، مما يجعلها أداة فعالة في مجالات متعددة، بما في ذلك التنبؤ بالفيضانات [4]. يعتمد الذكاء الاصطناعي، وبالتحديد تقانات تعلم الآلة، على تحليل مجموعة متنوعة من البيانات، مثل الأنماط المناخية، مستويات المياه في الأنهار، والبيانات التاريخية المتعلقة بالفيضانات [5,6].

فيما يتعلق بنهر الكبير الشمالي في سورية، يعد نقطة اهتمام مهمة؛ حيث يُعد من الأنهار الأكثر عرضة للفيضانات في الساحل السوري نتيجة للتغيرات المناخية. تشير المعلومات إلى أن الفيضانات في المناطق المحيطة بالنهر تُسبب أضراراً كبيرة في البنية التحتية والمجتمعات المحلية، وتجنباً لتكرار ما حصل في الأعوام السابقة من كوارث وخسائر فادحة لحقت بالأهالي والمزارعين بسبب العواصف المطرية الشديدة المتلاحقة التي أدت إلى جريانات كبيرة في النهر مسببة كوارث لاحقة. من هنا تأتي أهمية البحث في تطوير استراتيجيات فعالة لإدارة المخاطر باستخدام تقانات الذكاء الاصطناعي ونماذج التعلم الآلي (ML). استخدمت الدراسة تقانات نظم المعلومات الجغرافية (GIS) لتحليل المواقع وفهم الخصائص الجغرافية التي تؤثر على تدفق المياه، مع تحديد المناطق الأكثر عرضة للفيضانات. أخيراً يشدد الباحثون على أهمية التعاون بين العلماء وصانعي السياسات لدمج نتائج البحث في استراتيجيات إدارة المخاطر. هذا التعاون ضروري لتطوير استراتيجيات فعالة لإدارة الفيضانات والتخطيط للبنية التحتية ورفع مستوى الوعي المجتمعي [7].

أهمية البحث وأهدافه:

تتمثل أهمية هذا البحث في تعزيز دقة التنبؤ بالفيضانات من خلال التكامل بين تقنيات الذكاء الاصطناعي ونظم المعلومات الجغرافية (GIS)، مما يساهم في تقليل مستوى عدم اليقين المرتبط بالظروف الهيدرولوجية. يُمكن هذا التكامل الجهات المختصة من تحسين كفاءة اتخاذ القرار والاستجابة السريعة أثناء الأزمات، من خلال توفير بيانات


تحليلية دقيقة وموثوقة. كما يُسهم في ترشيد الوقت والجهد، وتعزيز فعالية استراتيجيات إدارة الفيضانات، بما يدعم حماية الأرواح والممتلكات والحد من الآثار السلبية للكوارث الطبيعية. ويتجسد هدف البحث الأساسي في:

1. تحديد العوامل الحاسمة في إدارة مخاطر الفيضانات في ظل التغيرات المناخية والتحديات المرتبطة بها
2. مقارنة فعالية نماذج الذكاء الاصطناعي وتقنيات التعلم الآلي (ML) مثل الانحدار الخطي Linear Regression، الأشجار العشوائية Random Forest، Extreme Gradient Boosting، Light Gradient Boosting، شجرة القرار Decision Tree و Extra Trees لتحديد النموذج الأكثر كفاءة في التنبؤ بالفيضانات.

طرائق البحث ومواده:

1.1 منطقة الدراسة

تشمل منطقة الدراسة الموضحة بالشكل 1 الحوض الساكب لنهر الكبير الشمالي الواقع في الجزء الشمالي من الساحل السوري، حيث تمتد حدود الحوض بين خطي طول $35^{\circ} 45' 40''$ و $36^{\circ} 15' 05''$ شرق خط غرينتش، وخطي عرض $35^{\circ} 59' 00''$ و $35^{\circ} 28' 30''$ شمال خط الاستواء. تبلغ المساحة الإجمالية للحوض نحو 1097 كم^2 ، ويصل الطول الكلي للنهر الرئيسي إلى حوالي 85.6 كم. وتتميز المنطقة بتنوع طبوغرافي واضح، إذ تتراوح الارتفاعات ما بين 0 و 1700 متر فوق سطح البحر، ما يسمح بتقسيم الحوض إلى ثلاث وحدات ارتفاعية رئيسية تشمل: منطقة سهلية منخفضة يتراوح ارتفاعها بين 0 و 100 متر، ومنطقة تلالية متوسطة يتراوح ارتفاعها بين 100 و 600 متر، إضافة إلى منطقة جبلية عالية تتراوح ارتفاعاتها بين 600 و 1700 متر [23].




الشكل 2: منطقة الدراسة

1.2 المنهجية:

تتألف المنهجية المستخدمة من أربع خطوات أساسية الشكل 2:

1. جمع البيانات وتحضيرها باستخدام برنامج ArcGIS pro 3.
2. اعداد مجموعات التدريب.
3. تدريب النماذج وتقييمها.
4. اختيار النموذج الأفضل الملائم للتنبؤ بالفيضان.



الشكل 3: المنهجية

1.2.1 المرحلة الأولى إنشاء قاعدة بيانات جغرافية مكانية وهيدرولوجية تحتوي جميع المعايير المطلوبة
 تُعدّ الفيضانات من الظواهر الطبيعية المعقّدة الناتجة عن تفاعل مجموعة من العوامل الفيزيائية، والأنثروبولوجية، والمناخية [2]. وبالأستناد إلى مراجعة الأدبيات والدراسات السابقة [8-12]، تم اعتماد مجموعة عوامل مؤثرة في تحليل خطر الفيضانات، من خلال دراسة الخصائص الجيومورفولوجية والبيئية والمناخية ذات الصلة، وتشمل هذه العوامل:

- الارتفاع (Elevation)
- الميل (Slope)
- انحناء المستوى (Plan Curvature)
- تراكم الجريان السطحي (Flow Accumulation)
- عامل الطول-الانحدار (Length-Slope Factor – LS Factor)
- كمية الهطول المطري (Rainfall)
- مؤشر الرطوبة الطبوغرافي (Topographic Wetness Index – TWI)
- مؤشر وعورة التضاريس (Terrain Ruggedness Index – TRI)
- مؤشر الوضع التضاريسي (Topographic Position Index – TPI)
- مؤشر طاقة الجريان (Stream Power Index – SPI)

- كثافة شبكة المسيلات المائية (Drainage Density – DD)
 - المسافة عن الأنهار (Distance from Rivers)
 - المسافة عن الطرق (Distance from Roads)
 - الليتولوجيا
 - مؤشر الغطاء النباتي (Normalized Difference Vegetation Index – NDVI)
 - استخدامات الأراضي (Land Use Land Cover – LULC)
- تعكس هذه المعايير مختلف الأبعاد الجغرافية والبيئية المرتبطة بمخاطر الفيضانات، وقد تم توظيفها لبناء نموذج تنبؤي متكامل يعتمد على تقنيات نظم المعلومات الجغرافية (GIS) وأساليب الذكاء الاصطناعي.

1.2.1.1 الارتفاع

يعد الارتفاع الشكل (3a) من العوامل المهمة في تقييم ظاهرة الفيضانات [14]، تعد المناطق المرتفعة من العوامل الأساسية في تصنيف الفيضانات، حيث تؤثر بشكل كبير على اتجاه وكميات الجريان السطحي. وفقاً للدراسات المختلفة، يُمكن تحديد الارتفاعات باستخدام مؤشرات محددة [15]، كما أن التغيرات في المرتفعات تتفاعل مع عوامل أخرى تؤثر على حدوث الفيضانات (تم استعمال النموذج الارتفاعي DEM بدقة 30 متر)، حيث تتركز المناطق المرتفعة في شرق الحوض، وتتحول إلى مناطق منبسطة في الأجزاء الجنوبية.

1.2.1.2 الميل

يعد الميل الشكل (3b) عاملاً أساسياً في الدراسات المتعلقة بحساسية الفيضانات منذ ثلاثينيات القرن الماضي. حيث يؤثر بشكل مباشر على سرعة الجريان السطحي ونفاذية التربة، كما يحدد كمية تسرب المياه إلى التربة، مما يؤثر بدوره على عمق التربة وقدرتها على الاحتفاظ بالمياه [8، 10]، يتراوح الميل في منطقة الحوض بين القيم المنخفضة المركزة في الأجزاء الجنوبية وصولاً إلى قيم مرتفعة في الأجزاء الشمالية والشرقية والغربية.

1.2.1.3 انحناء المستوى Plan Curvature

يُعرف انحناء المستوى الشكل (4f) معدل تغير ميل المنحدر أو الاتجاه، ويتم حسابه بناءً على نصف قطر الانحناء في ذلك الاتجاه، حيث يُمثل الانحناء القيمة المقلوبة لنصف القطر. بالتالي، تظهر المنحنيات الواسعة عادةً بشكل معتدل، بينما تُظهر المنحنيات الضيقة انحناءً أكبر. يؤثر انحناء المستوى في الفيضانات من خلال تحكمه في العوامل البيئية، مثل كمية الأمطار وتطور الغطاء النباتي ومحتوى التربة، مما يؤثر على شدة وتوقيت هذه الظواهر [16].

1.2.1.4 مؤشر (NDVI):

يعرف مؤشر الغطاء النباتي الشكل (4a) بالمعادلة (1)، يلعب NDVI دوراً حيوياً في فهم الفيضانات وتأثيرها، ويُساعد على رصد التغيرات البيئية وتفاعل المياه مع البيئة، مما يُعزز من استراتيجيات إدارة الفيضانات في المناطق المعرضة للخطر، حيث تمثل NIR الأشعة تحت الحمراء القريبة و Red الأشعة الحمراء.

$$NDVI = (NIR - RED) / (NIR + RED) \quad (1)$$

1.2.1.5 تراكم التدفق (Flow Accumulation):

تُقدّر تقنية تراكم التدفق التراكمي المرجع من خلال احتساب الأوزان الإجمالية لجميع الخلايا المتدفقة نحو كل خلية منخفضة ضمن مخرجات أداة تراكم التدفق، تعد المناطق التي تشهد تراكماً عالياً للتدفق مناطق ذات تركيز مرتفع [17]، ويمكن استخدامها لتحديد حدود قنوات المياه الشكل (4c).

1.2.1.6 مؤشر الرطوبة الطبوغرافي (Topographic Wetness Index (TWI)

يعد مؤشر الرطوبة الطبوغرافية (TWI) أداة أساسية لتحديد سعة رطوبة التربة، حيث يُظهر مستوى تشبع المياه في المواقع المختلفة بناءً على تضاريسها وحركتها نحو المستويات الأقل ارتفاعاً بفعل قوى الجاذبية الشك(4d). تُظهر الدراسات أن التغيرات في كمية الجريان مرتبطة بأنواع التضاريس المختلفة، مما يؤثر على سلوك الجريان وأنماطه، وتم تقديم مفهوم TWI من قبل Kirkby و Beven في عام 1979، حيث أكدوا على أهمية عوامل هندسة الميل وزاوية الميل ومساحة حوض المياه في تحديد حجم الحوض. يُحتسب TWI باستخدام المعادلة (2)، حيث α هو تراكم التدفق و c زاوية الميل.

$$(2) \quad TWI = \ln \left(\frac{(\alpha + 1) * cellsize}{\tan c} \right)$$

1.2.1.7 عامل LS (طول الميل وعامل انحدار الميل) Length-Slope factor

يعد عامل LS عنصراً أساسياً في تحليل البيانات المائية والمناطق التضاريسية، حيث يدمج بين طول الميل وزاوية الانحدار، مما يعزز تقييم تأثير الانحدارات على معدل جريان المياه وعمليات التآكل، وتم إعداد خريطة "LS" شكل(4e) باستخدام المعادلة (3) وفقاً لدراسة [18]:

$$(3) \quad LS = (fac * \frac{cellsize}{22.31})^{0.4} * (\sin \theta / 0.0896)^{1.3}$$

يمثل "fac" تراكم التدفق، والذي يتم حسابه استناداً إلى البيانات الرقمية للارتفاع (DEM)، و θ زاوية الميل بالدرجات.

1.2.1.8 الهطول المطري

تعد الأمطار من العوامل الأساسية التي تؤثر بشكل كبير على حدوث الفيضانات، حيث إنها الشرط الضروري لوقوع هذه الظواهر. إن كميات الأمطار ومدة هطولها تلعبان دوراً محورياً في تشكيل الفيضانات، تؤثر شدة الأمطار وطول فترة هطولها بشكل مباشر على ارتفاع منسوب المياه وعمليات انجراف الرواسب، وهذا بدوره يسهم في زيادة احتمالية حدوث الفيضانات وتفاقم آثاره [14، 20]، تم الاعتماد على بيانات من ست محطات أرصاد جوية موزعة ضمن حوض نهر الكبير الشمال وتشمل: محطة عين التينة، عين عيدو، سلمى، اللانقية، كسب، والحفة، وتم تحليل بيانات الهطول المطري اليومي الأعظمي خلال فترة تمتد لخمس سنين، وذلك بهدف دراسة الظواهر القصوى المتعلقة بالأمطار الشكل (3h).

1.2.1.9 مؤشر الوعورة التضاريسي (Terrain Roughness Index (TRI)

يعد مؤشر الوعورة التضاريسي (TRI) مقياساً لتقييم مدى وعورة التضاريس في المنطقة، ويتم حسابه من خلال حساب الفروقات في الارتفاع بين النقاط المجاورة على السطح الشكل (3g) تُظهر القيم المرتفعة جداً للمؤشر إلى مناطق ذات تضاريس أكثر تعقيداً وتبايناً، والقيم المنخفضة إلى تضاريس منبسطة [13].

1.2.1.10 مؤشر الوضع التضاريسي (Topographic Position Index (TPI)

يعد مؤشر الوضع التضاريسي (TPI) أداة تحليلية لقياس الموقع النسبي للأرض ضمن محيطها، مع مراعاة اختلافات الارتفاع. يُستخدم TPI لتحديد ما إذا كانت المنطقة تقع على قمة تل، أو منحدر، أو في قاع وادي الشكل(3e) تظهر القيم الإيجابية إلى المناطق الجبلية العالية، بينما تشير القيم السلبية إلى المناطق المنخفضة، والقيم القريبة من الصفر تدل على السهول. كما يعد TPI أداة فعالة في تقييم قابلية الفيضانات، حيث يحدد المناطق الأكثر عرضة للفيضانات بناءً على ارتفاعها وخصائص التضاريس المحيطة [14].

1.2.1.11 مؤشر طاقة الجريان (SPI) The Stream Power Index

يعد مؤشر طاقة الجريان (SPI) معلمة هيدرولوجية حيوية تُستخدم لرسم خرائط تعرض الفيضانات الشكل (3f)، حيث يساهم في تقييم الطاقة المحتملة المتاحة في نظام المجرى المائي وتأثيره على التآكل ونقل الرواسب، يعد مؤشر طاقة الجريان (SPI) عاملاً أساسياً لتقييم تعرض المنشآت المائية المتواجدة تحت الماء للمخاطر [14]. تُستخدم المعادلة (4) لتوليد خرائط SPI، مما يعزز من فهم العمليات الهيدرولوجية والتضاريسية في النظام البيئي، حيث α تراكم التدفق و β الميل

$$SPI = \alpha * \tan \beta * 0.17453 \quad (4)$$

1.2.1.12 كثافة المسيلات المائية Drainage Density

تؤثر أنظمة الصرف على فيضان النهر والفيضانات المستمرة في منطقة ما، أن ارتفاع كثافة التصريف الشكل (3d) قد يؤدي إلى زيادة الفيضانات وارتفاع مستويات الجريان السطحي [20]. تتأثر الكثافة بالنشاط المناخي، حيث تتأثر خصائص كل منطقة بالعوامل الجغرافية، والنباتات، ونوع التربة، والميل، ومعدل النفاذية. توجد علاقة إيجابية بين هطول الأمطار والجريان السطحي على مستوى الحوض [14].

1.2.1.13 المسافة من الطرق:

تشير الدراسات [14،8] إلى أن المسافة من الطرق تؤثر بشكل ملحوظ على تآكل التربة، سواء بالقرب من الطريق أو على جوانب المنحدرات المتأثرة بالطرق. تلعب عوامل مثل الحفر، والتغيرات في الأحمال الزائدة، والهيدرولوجيا، والجريان السطحي، دوراً حيوياً في تغيير شكل المنحدرات، مما يؤثر بدوره على الضغط الناتج عن توازن المنحدر. تم إنشاء خمس مناطق عازلة مستقلة على طول امتداد الطريق بهدف تقييم تأثير الطرق على استقرار المنحدرات الشكل (4b).

1.2.1.14 المسافة من النهر والمسيلات المائية:


تعد المسافة من الأنهار الشكل (3c) أحد العوامل الرئيسية المؤثرة على الفيضانات [14]، كما أن قرب المنحدر من المسيلات المائية يؤثر على استقراره. يمكن أن يؤدي تآكل المنحدر أو تشبع الطبقات السفلية بالماء إلى زيادة مستويات الفيضانات في المناطق القريبة من ضفاف الأنهار [18].

1.2.1.15 استخدام الأراضي LULC:


يمكن أن تؤثر استخدام الأراضي الشكل (4g) بشكل غير مباشر أو مباشر على الجريان السطحي والتبخر، كما أشار المرجع [20] في المناطق الخضراء يؤدي نقص الغطاء النباتي إلى نقص في التحكم في التدفق السريع، مما يساهم في زيادة الجريان السطحي. يمكن أن يؤدي بناء الهياكل بالقرب من حوض النهر إلى تدمير كبير خلال الأحداث الفيضانية.

1.2.1.16 الليتولوجيا:

تعد الليتولوجيا الشكل (4h) عاملاً أساسياً في فهم آليات الفيضانات وتوقعها، حيث تؤثر بشكل مباشر على أنماط تدفق المياه وتصريفها، تُعد الخصائص الجيولوجية والتربة ذات تأثير كبير على قدرة التربة على الاحتفاظ بالمياه ومدى تصريفها، مما يساهم في تجميع المياه السطحية. كما أن التغيرات الناتجة عن الأنشطة البشرية، مثل تغيير استخدام الأراضي بسبب الزراعة أو البناء، تؤثر على الأنماط وتعزز من إمكانية تعرض المناطق للفيضانات [14].



الشكل 4: (a) الارتفاع (b) الميل (c) البعد عن الأنهار (d) كثافة النهر (e) مؤشر الوضع التضاريسي (f) مؤشر طاقة الجريان (g) مؤشر الوعورة التضاريسي (h) الهطول المطري



الشكل 5: (a) NDVI، (b) البعد عن الطريق، (c) تراكم التدفق، (d) مؤشر الرطوبة الطبوغرافي، (e) عامل LS، (f) انحناء المستوى، (g) LULC، (h) الليتولوجيا

النتائج والمناقشة:

1.3 تحليل ومعالجة البيانات:

1.3.1 الطرق الهجينة بالذكاء الاصطناعي:

تزايدت أهمية الطرق الهجينة بالذكاء الاصطناعي في مجال التنبؤ بالفيضانات، حيث تُعد تقانات مبتكرة قادرة على تحليل كميات ضخمة من البيانات واستخراج الأنماط المعقدة المرتبطة بخطر الفيضانات. تعتمد هذه الأدوات على نماذج، التي تستطيع التعلم من بيانات تاريخية ووقتية تشمل معلومات حول الأحوال الجوية، الهطول المطري، وخصائص المناطق الجغرافية. من خلال جمع وتحليل هذه البيانات، تتمكن نماذج التعلم الآلي من التعرف على الأنماط المتكررة، مما يساعد في تقييم كيفية تأثير العوامل مثل الأمطار الغزيرة ومعايير أخرى على التنبؤ بحدوث فيضان. تقوم نماذج التعلم الآلي بتقديم تنبؤات دقيقة حول احتمالية حدوث الفيضانات، بما في ذلك توقيت الفيضانات وشدها، مما يتيح للسلطات المحلية اتخاذ تدابير استباقية لتقليل من الأضرار، تحسن التنبؤات تحسن من استجابة الطوارئ والمساهمة في إنقاذ الأرواح وتقليل الخسائر المادية، وأظهرت دراسات أن استخدام تقانات التعلم الآلي في النمذجة الهيدرولوجية قد أدى إلى تحسينات ملحوظة في دقة التنبؤات بالمقارنة مع الطرق التقليدية [22]. علاوة على ذلك، توفر أدوات التعلم الآلي القدرة على التقييم المستمر من خلال تحديث التوقعات بناءً على البيانات الجديدة، مما يجعلها أداة حيوية للمجتمعات المعرضة لمخاطر الفيضانات، في هذه الدراسة تم المقارنة بين النماذج التالية:

1. الانحدار الخطي (Linear Regression)

نموذج إحصائي يُستخدم لتمثيل العلاقة بين متغير تابع واحد ومتغيرات مستقلة متعددة باستخدام دالة خطية.

2. الأشجار العشوائية (Random Forest)

خوارزمية تعلم آلي تعتمد على إنشاء مجموعة من أشجار القرار (decision trees) لاستنتاج قيمة المتغيرات المستهدفة، سواء كانت متغيرات كمية أو نوعية. تُولد كل شجرة بناءً على عينة عشوائية من البيانات وتستخدم جزءاً من الخصائص المتاحة في كل انقسام. يتم تجميع التوقعات الناتجة عن هذه الأشجار من خلال عملية التصويت أو المتوسط، مما يعزز الدقة ويقلل من التجاوز. هذه الخوارزمية فعالة في مواجهة البيانات ذات الأبعاد العالية والتداخلات المعقدة.

3. XGBoost

تعد خوارزمية XGBoost إحدى أكثر خوارزميات التعلم الآلي المستخدمة في التطبيقات الفعلية. تعتمد على مبدأ تعزيز التدرجات (gradient boosting)، حيث يتم بناء النموذج كطيف من الأشجار حيث تصحح كل شجرة الأخطاء التي ارتكبتها الأشجار السابقة. كما تتميز هذه الخوارزمية بسرعتها وكفاءتها في معالجة البيانات الكبيرة، بالإضافة إلى تقديمها مجموعة من المميزات القابلة للتعديل لتحسين الأداء، مما يسهل استخدامها في المسابقات.

4. Light GBM

خوارزمية حديثة تهدف إلى تحسين الأداء مقارنةً بـ XGBoost وتعتمد على تقانات مثل تجزئة الهدف (Gradient-based One-Side Sampling) والتجميع الحصري للميزات (Exclusive Feature Bundling) لتقليل زمن التدريب وزيادة كفاءة الذاكرة. تتيح Light GBM التعامل مع مجموعات بيانات ذات حجم كبير بشكل فعال، مما يجعلها خياراً مثالياً في التطبيقات التي تتطلب سرعة تحرير البيانات الكثيفة.

5. شجرة القرار (Decision Tree)


شجرة القرار هي نموذج يتم استخدامه في التعلم الآلي لتصنيف أو تقدير القيم من خلال تقسيم البيانات إلى مجموعات فرعية قائمة على الاستجابات للأسئلة المتعلقة بخصائص البيانات. يتم بناء الشجرة بدءاً من جذر واحد ينتشر إلى عدة مستويات بناءً على الاختبارات المنطقية. توفر شجرة القرار طريقة بسيطة وسهلة الفهم لتحليل البيانات، لكنها قد تتعرض للتجاوز (overfitting) إذا لم تُستخدم بشكل صحيح، مما يستدعي اللجوء إلى تقانات مثل التحجيم أو التجميع لتحسين أدائها.

6. Extra Trees

الأشجار الإضافية (Extremely Randomized Trees) هي خوارزمية تدرج تحت فئة التعلم الجماعي وتعتمد على إنشاء مجموعة من أشجار القرار بطريقة عشوائية أكثر. يتم اختيار النقاط والانقسامات بطريقة عشوائية بشكل كبير، مما يؤدي إلى سرعة أعلى في تدريب النموذج مقارنةً بالأشجار العشوائية التقليدية. تُستخدم هذه التقنية عادةً للتقليل من التجاوز وتحسين الأداء في حالات البيانات كبيرة الحجم، على الرغم من أنها قد تكون أقل تفسيراً مقارنةً بالنماذج الأخرى.

1.3.2 خريطة خطر الفيضانات

يتم التعبير عن مفهوم مخاطر الفيضانات من خلال عنصرين رئيسين: الخطر والضعف. ويتم تمثيل هذه العلاقة في المعادلة (خطر الفيضانات = الخطر * الضعف)، استندت خريطة الخطر على البيانات السابقة، وتم تطبيق تقانات نظام المعلومات الجغرافية (GIS) لتحليل هذه البيانات وتحديد العلاقات المكانية بينها [23]، وتم استخدام عملية التحليل الهرمي (AHP) لتعيين الأوزان للمؤشرات المدخلة بالاعتماد على مقياس ساعتاني [24]، مما يعزز من اتخاذ قرارات قائمة على التحليل المكاني وتحليل القرار متعدد المعايير (MCDA)، وتم تصنيف الناتج النهائي إلى خمس فئات تعكس درجات الخطورة المحتملة: منخفضة جداً (Very Low)، منخفضة (Low)، متوسطة (Moderate)، مرتفعة (High)، ومرتفعة جداً (Very High) الشكل (5).




الشكل 6: خريطة Risk

1.3.3 إعداد مجموعات بيانات التدريب

تم تقسيم نقاط خريطة الفيضانات إلى قسمين لاستخدامهما في التدريب والتحقق. في هذا السياق، تم تخصيص 70% لمجموعة بيانات التدريب، في حين تم تخصيص 30% المتبقية لمجموعة بيانات التحقق. يستلزم رسم خرائط تعرض الفيضانات باستخدام تقانات التعلم الآلي تنفيذ تصنيف ثنائي، مما يتطلب توافر مواقع الفيضانات وغير الفيضانات بشكل متزامن، بناءً عليه تم اختيار 150 موقع فيضاني و100 موقع غير فيضاني من مناطق نقل فيها احتمالية الفيضانات بالاعتماد على خريطة الخطر السابقة الشكل (6).

جُهزت كل نقطة بقيم المتغيرات الهيدرولوجية والبيئية الأساسية (كالهطول المطري، وخصائص التربة، والانحدارات التضاريسية، الخ)، والتي تُستخدم كمدخلات للنموذج.



الشكل 7: نقاط التدريب

1.3.4 اختبار النماذج وتقييمها

تعد ميزة "تدريب باستخدام AutoML" في ArcGIS Pro أداة فعالة لبناء نماذج تعلم آلي من خلال أتمتة مراحل عملية التدريب. تشمل هذه العملية التحليل الاستكشافي للبيانات، اختيار الميزات، ضبط المعلمات، تم تقييم أداء النماذج باستخدام المعايير التالية كما هو موضح في الجدول (1):

1. الدقة (Accuracy): تُعرف كنسبة التنبؤات الصحيحة إلى إجمالي عدد التنبؤات التي تم إجراؤها، وتتراوح القيم بين 0 و1 وكلما اقتربت القيمة من الواحد، كان أداء النموذج أفضل، وتشير دقة بنسبة 85% إلى أن النموذج نجح في توقع 85% من العينات في مجموعة الاختبار.
2. الحساسية (Precision): وهي نسبة الحالات الإيجابية الصحيحة من إجمالي التنبؤات الإيجابية التي تم إجراؤها. توضح هذه النسبة عدد الحالات التي تم تصنيفها كإيجابية والتي كانت بالفعل إيجابية، وتتراوح القيم بين 0 و1 وكلما اقتربت القيمة من الواحد، كان أداء النموذج أفضل.

3. الاسترجاع (Recall): وهو مقياس لنماذج التصنيف، يجب على السؤال: عندما كانت الحقيقة الأساسية هي الفئة الإيجابية، ماهي النسبة المئوية للتنبؤات التي حددها النموذج بشكل صحيح على انها فئة إيجابية، وتتراوح القيم بين 0 و 1 وكلما اقتربت القيمة من الواحد، كان أداء النموذج أفضل.

4. درجة (F1 Score): يجمع مقياس التقييم درجة F1 بين الحساسية والاسترجاع كمقياس لفعالية التصنيف.

5. Logloss (Loss Function): يُستخدم لتقييم مدى دقة التوقعات بدلالة الاحتمالات، ويحسب مقدار عدم التوافق بين القيم المتوقعة والقيم الحقيقية، وكلما كانت القيمة أقل، كان أداء النموذج أفضل.

لعدم توفر بيانات فيضانات تاريخية موثوقة مستقلة، تم استخدام خريطة خطر الفيضانات التي أُعدت مسبقاً من خلال تحليل متعدد المعايير (Multi-Criteria Analysis) باعتبارها القيم الحقيقية (Ground Truth) لمجموعة البيانات. تم تدريب النماذج واختبارها ومقارنة مخرجات النماذج (Predicted Labels) مع القيم الحقيقية (True Labels) المستندة إلى خريطة الخطر عبر مصفوفة الالتباس (Confusion Matrix)، التي استُخرجت منها مؤشرات الأداء، وتشير نتائج الجدول (1) إلى تفوق نموذج Linear على باقي النماذج، حيث حقق أعلى القيم في مؤشرات الدقة والاسترجاع و F1، وسجل أدنى قيمة لـ Logloss (0.0188)، مما يدل على موثوقية عالية في التنبؤ واحتمالية منخفضة للخطأ، ورغم أن النماذج المعتمدة على الأشجار والتعزيز (مثل XGBoost و LightGBM و Random Forest) غالباً ما تُستخدم لمعالجة البيانات المعقدة التي تتضمن تفاعلات غير خطية بين المتغيرات، إلا أن تفوق النموذج الخطي هنا يُعزى إلى وجود علاقات خطية واضحة بين المتغيرات المستقلة والمتغير الهدف، وجودة البيانات وتجانسها، ما قلل من الحاجة إلى نماذج معقدة، كفاءة اختيار الخصائص المدخلة ضمن النموذج، انخفاض التراكب بين المتغيرات وضعف التشويش في البيانات، بناءً على ما سبق يُعد نموذج الانحدار الخطي الأنسب في هذا السياق، ويُوصى باستخدامه كأساس لتقدير قابلية التعرض للفيضانات.


الجدول 1: يوضح المقارنة بين النماذج

النموذج	Accuracy	Precision	Recall	F1 Score	Logless
Dicision Tree	0.932	1	0.885	0.939	0.942
Linear	1	1	1	1	0.018
LightGBM	0.977	1	1	0.981	0.192
Xgboost	0.591	0.591	1	0.743	0.246
Random Forest	0.977	0.963	1	0.981	0.060
Extra Trees	0.977	1	1	0.98	0.050


1.3.5 خريطة قابلية الفيضان:

تم الاعتماد على نموذج Linear وتم تقييم أدائه باستخدام منحنى ROC وقيمة AUC (الشكل 9)، أظهر النموذج قدرة جيدة على التمييز بين المناطق المعرضة وغير المعرضة لخطر الفيضانات. كما تم تحليل مصفوفة الالتباس (Confusion Matrix) (الشكل 8)، والتي بينت توافقاً مقبولاً بين القيم المتوقعة والبيانات الفعلية، مما يعكس كفاءة النموذج وانخفاض نسبة الخطأ. وبعد التحقق من دقته وخلوه من التحيز أو الإفراط في التدريب، تم تصدير نتائجه إلى برنامج نظم المعلومات الجغرافية (Arcmap) لتمثيل المناطق المصنفة وفق درجات الخطورة، كما هو موضح في الشكل (7)، وتشير الخريطة الناتجة إلى تركيز المناطق عالية الخطورة في الجزء الجنوبي والجنوب الغربي من الحوض، بينما تقع المناطق الأقل خطورة في الشمال والشمال الشرقي.


وتُظهر نتائج التحليل المكاني المقارن وجود درجة واضحة من التوافق بين خريطة التنبؤ بالفيضانات المستندة إلى نموذج الذكاء الاصطناعي وخريطة الخطر، حيث يلاحظ تطابق مكاني ملحوظ في تحديد بعض البؤر ذات الحساسية العالية، لا سيما في المناطق ذات الخصائص الطبوغرافية والهيدرولوجية المتقاربة، وسُجِلت بعض الفروقات الثانوية التي يمكن إرجاعها إلى اختلاف الأساليب التحليلية المعتمدة في كل منهجية، ويُعزز هذا التوافق المكاني النسبي من مصداقية النموذج المقترح، ويؤكد قدرته على محاكاة الواقع الجغرافي بدقة مقبولة.



الشكل 8: خريطة قابلية الفيضان



الشكل 10: اختبار roc_curve و AUC



الشكل 9: مصفوفة التشتت للنموذج الخطي

الاستنتاجات والتوصيات:

الاستنتاجات:

1. أظهرت نتائج المقارنة بين ستة نماذج من خوارزميات التعلم الآلي أن نموذج الانحدار الخطي (Linear Regression) قدّم الأداء الأفضل في منطقة حوض نهر الكبير الشمالي، وذلك استناداً إلى مؤشرات التقييم المعتمدة واستخدام عينات تدريب مأخوذة من خريطة الخطر.
2. بيّنت الدراسة أن استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في نمذجة الفيضانات ضمن بيئة AutoML يعزز من دقة التنبؤات المكانية، ويساهم بشكل فعال في تحسين الاستجابة المبنية على المعرفة لمواجهة الأزمات الناتجة عن الفيضانات.
3. قدّم دمج نظم المعلومات الجغرافية (GIS) مع نماذج التنبؤ بالفيضانات نتائج إيجابية، حيث يمكن تحليل العوامل البيئية والجغرافية بشكل متكامل لتحقيق تنبؤات أكثر دقة فيما يخص بفيضانات نهر الكبير الشمالي.
4. استخدام مجموعة متنوعة من المعايير البيئية والجغرافية والهيدرولوجية ضمن نموذج واحد ساعد على تحديد مناطق الخطورة العالية بدقة، وبيّن أن التكامل بين هذه العوامل يعزز من كفاءة النمذجة في سياق التغيرات المناخية المتسارعة.

التوصيات:

1. توسيع نطاق جمع البيانات: يُوصى بتعزيز جهود جمع البيانات المتعلقة بفيضانات المنطقة من مختلف المصادر الموثوقة، بما في ذلك تحديث السجلات المناخية وإجراء مراقبة مستمرة، وإنشاء محطات قياس للتدفقات.
2. تطوير نماذج تنبؤ مبتكرة: يشمل ذلك استخدام تقنيات مثل التعلم الآلي والذكاء الاصطناعي لتحسين دقة النماذج الحالية واستكشاف طرق جديدة للتنبؤ.
3. التدريب على تقنيات جديدة: ينبغي تقديم برامج تدريبية للمتخصصين في مجال إدارة المخاطر لتعزيز مهاراتهم في استخدام نظم المعلومات الجغرافية ونماذج التنبؤ.

4. يُوصى باستخدام تقانات التعلم العميق (Deep Learning)، وخاصة الشبكات العصبية العميقة (Deep Neural Networks)، لما لها من قدرة على تحسين دقة التنبؤ بمخاطر الفيضان في الحوض المدروس، من خلال تحليل العلاقات المعقدة وغير الخطية بين المتغيرات البيئية والهيدرولوجية.
5. إجراء دراسة مقارنة منهجية بين تقنيات الذكاء الاصطناعي والنماذج الرياضية التقليدية بهدف تحديد الأنسب لتحليل وتوقع مخاطر الفيضانات في البيئات الجغرافية المختلفة.

References:

- [1] I.D. Hassan, A mathematical model for the river flow between the northern dam and the bridge Khan Attallah, *Tishreen University Journal-Engineering Sciences Series* (in Arabic). Vol. (20), No. (6-7), (1998).
- [2] B.T. Pham, A. Jaafari, T.V. Phong, et al. Improved flood susceptibility mapping using a best first decision tree integrated with ensemble learning techniques, *Geosciences Frontiers*. Vol. (12) No. (3), pp. 101-105, (2021).
- [3] C.M. Bishop. *Pattern Recognition and Machine Learning*, Springer, 2006.
- [4] R. Leander, F. Jaramillo. *Application of Machine Learning Techniques for Flash Flood Prediction*, Journal of Hydrology, 2018.
- [5] Z. Yin, P. Chen, L. Wang. A Machine Learning Approach for Flood Prediction, *Water*, Vol. (11), No. (1), (2019).
- [6] D.T. Bui, P. Tsangaratos, P.T.T. Ngo, T.D. Pham, B.T. Pham. Flash flood susceptibility modeling using an optimized fuzzy rule-based feature selection technique and tree-based ensemble methods, *Science of the Total Environment*. Vol. (668), pp. 1038–1054, (2019).
- [7] Y. Wang, Z. Fang, H. Hong, et al. Flood susceptibility mapping by integrating frequency ratio and index of entropy with multilayer perceptron and classification and regression tree, *Journal of Environmental Management*. Vol. (289), pp. 112-449, (2021).
- [8] S. Lee, F. Rezae. Data used for GIS-based Flood Susceptibility Mapping. Data of Geology, Ecology, Oceanography, *Space Science and Polar Science*. Vol. (4) No. (1), pp. 1–15, (2022).
- [9] C. Luu, et al. Flood-prone area mapping using machine learning techniques: a case study of Quang Binh province, Vietnam, *Natural Hazards*. Vol. (108) No. (3), pp. 3229–3251, (2021).
- [10] U. Pawar, W. Suppawimut, N. Muttit, U. Rathnayake. A GIS-Based Comparative Analysis of Frequency Ratio and Statistical Index Models for Flood Susceptibility Mapping in the Upper Krishna Basin, India, *Water*. Vol. (14), pp. 1-18, (2022).
- [11] V. Isazade, A.B. Qasimi, A. Alkafy, P. Dong, M. Mohammadi. Simulation of flood-prone areas using machine learning and GIS techniques in Samangan Province, Afghanistan, *Geodesy and Cartography*. Vol. (50) No. (1), pp. 20-29, (2024).
- [12] E.H. Ighile, H. Shirakawa, H. Tanikawa. *Application of GIS and Machine Learning to Predict Flood Areas in Nigeria*, Sustainability, Vol. (14), p. 5039, (2022).
- [13] S.A.H. Weisscher, A.W. Baar, J. Vanbelzen, et al. Transitional polders along estuaries: Driving land-level rise and reducing flood propagation, *Nature-Based Solutions Journal*. Vol. (2), p. 100022, (2022).
- [14] N.I. Saikh, P. Mondal. GIS-based machine learning algorithm for flood susceptibility analysis in the Pagle River basin, Eastern India, *Natural Hazards Research*. Vol. (3), pp. 420-436, (2023).

- [15] A. Tiryaki, M. Karaca. Influence of Elevation on Surface Runoff Characteristics, *Journal of Environmental Management*. Vol. (227), pp. 123-134, (2018).
- [16] E. Dodangeh, M. Panahi, F. Rezaie, S. Lee, D.T. Bui, C.W. Lee, B. Pradhan. Novel hybrid intelligence models for flood-susceptibility prediction: Meta optimization of the GMDH and SVR models with the genetic algorithm and harmony search. *Journal of Hydrology*. Vol. (590), pp. 125-423, (2020).
- [17] X. Wang, G. Kingslan, D. Poudel, A. Fench. Urban flood prediction under heavy precipitation, *J. Hydrol.* Vol. (577), pp. 123-984, (2019).
- [18] I.D. Moore, G.J. Burch. Sediment transport capacity of sheet and rill flow: application of unit stream power theory, *Water Resour. Res.* Vol. (22), pp. 1350-1360, (1986).
- [19] B. Choubin, E. Moradi, M. Golshan, et al. An ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines, *Sci. Total Environ.* Vol. (651), pp. 2087–2096, (2019).
- [20] K. Khosravi, H. Shahabi, B.T. Pham, et al. A comparative assessment of flood susceptibility modeling using Multi-Criteria Decision-Making Analysis and Machine Learning Methods, *Journal of Hydrology*. Vol. (573), pp. 311-323, (2019).
- [21] I.B. Huang, J. Keisler, I. Linkov. Multi-criteria decision analysis in environmental sciences: Ten years of applications and trends, *Sci. Total Environ.* Vol. (409), pp. 3578–3594, (2011).
- [22] T.L. Saaty. *The Analytic Hierarchy Process: Planning, Priority Setting, Resource Allocation*, McGraw-Hill, New York, 1980.
- [23] H. Magd. *Establishing a relationship to calculate the maximum discharge in the Northern kabir River Basin based on the logical method*, PhD thesis, Tishreen University (in Arabic), Syria, 2013.