

تقنيات تعلم الآلة ML ونظم المعلومات الجغرافية GIS في رسم خرائط مخاطر الفيضانات - حالة المسيلة. Machine learning and GIS techniques in flood Risk mapping-case study of M'sila.

تاھمي صادق^{1*}

¹ جامعة محمد بوضياف، المسيلة، الجزائر، sadsad067394@gmail.com

تاريخ القبول : 2023/08/02

تاريخ الاستلام : 2023/03/17

ملخص: تلعب نظم المعلومات الجغرافية GIS دورا هاما في توفير وتصميم خرائط الفيضانات واحتمالية حدوثها، خصوصا من خلال دمجها مع تقنيات التعلم الآلي ML الحديث، هدفت هذه الورقة البحثية لإبراز مدى أهمية الدمج بين التقنيتين في رسم خرائط مخاطر الفيضانات، ومن أجل تحقيق هذا الهدف قمنا بدراسة حالة مدينة المسيلة، التي تعد من بين أكثر المناطق في الجزائر عرضة لهذا النوع من الأخطار. توصلت هذه الأخيرة لرسم خريطة باستخدام نظم المعلومات الجغرافية لتحديد المناطق الأكثر عرضة لخطر الفيضانات في مدينة المسيلة وتحقيق الهدف المطلوب، وذلك بعد المقارنة بين نتائج 3 خوارزميات تعلم آلة ML، هي نموذج تعزيز التدرج الشديد xGboost، خوارزمية الغابة العشوائية Random Forest، وخوارزمية الجار الأقرب K Nearest Neighbor، حيث أعطت كل من هذه الخوارزميات معدل دقة معين Accuracy، بلغ هذا الأخير على التوالي % 97.92، % 95، % 93.75، أخيرا تم الاعتماد في عملية رسم الخريطة النهائية على النموذج الأول والذي أعطى أكبر دقة وهو نموذج xGboost.

الكلمات المفتاحية: نظم المعلومات الجغرافية GIS؛ تعلم الآلة ML؛ الفيضانات؛ نموذج تعلم الآلة.

Abstract:

Geographic Information Systems (GIS) play a vital role in providing and designing flood maps and their probability, especially through their integration with modern machine learning (ML) techniques. The aim of this research paper is to highlight the importance of the integration between these two technologies in drawing flood risk maps. In order to achieve this goal, we studied the case of the city of M'sila, which is one of the areas in Algeria most prone to this type of hazard.

The study resulted in drawing a map using GIS that identifies the most flood-prone areas in the city of M'sila and achieving the desired goal, after comparing the results of three machine learning algorithms, which are the extreme gradient boosting (xGboost) model, the random forest algorithm, and the k-nearest neighbor algorithm. Each of these algorithms gave a certain level of accuracy, with the latter reaching 97.92%, 95%, and 93.75%, respectively. Finally, the first model, which gave the highest accuracy, was used in the process of drawing the final map, which is the xGboost model.

Keywords: Geographic Information Systems (GIS); machine learning (ML); floods; machine learning model.

مقدمة :

تعتبر الفيضانات من الكوارث الطبيعية الأكثر تدميراً، إذ تسبب أضراراً جسيمة في الحياة البشرية والبنية التحتية والزراعة والنظام الاقتصادي والاجتماعي (Mosavi Amir et al, 2018)، فلقد أثرت على حياة ما يقارب 68 مليون شخص في شرق آسيا و 40 مليون في جنوبها، بينما في جنوب الصحراء الكبرى في إفريقيا تأثر 10 ملايين بالجفاف و 2 مليون بالفيضانات (تقرير التنمية البشرية، 2007 - 2008)، والأشخاص الذين يعيشون في سهول فيضية أو مياي غير مقاومة للفيضانات، أو الأشخاص الذين يفتقرون إلى نظم الإنذار والتوعية بمخاطر الفيضانات، هم الأكثر عرضة لخطر الفيضانات (منظمة الصحة العالمية، تم الاطلاع عليه في 2022).

تسعى جميع الدول في العالم اليوم إلى توفير أساليب وتقنيات يمكنها التنبؤ بحدوث الكوارث الطبيعية، من أجل التصدي لها، أو التخفيف من شدتها والتخطيط للتعاافي منها، وفي هذا الصدد تلعب نظم المعلومات الجغرافية GIS دوراً هاماً في توفير معطيات خرائطية وقواعد بيانات محينة بالإمكان استعمالها للاستشراف والتوقع والتسيير، والمتابعة الدقيقة لمختلف الظواهر الطارئة على المجال الحضري، وبالتالي تصور الأخطار المتوقعة وتقدير حجمها ومساراتها وخسائرها، ومحاولة الحد من آثارها (هاجر إبراهيمي وآخرون، 2021)، خصوصاً من خلال دمجها مع تقنيات التعلم الآلي ML الحديث، الذي يساعد البشر في أتمتة أو شبه أتمتة المهام اليدوية التقليدية، حيث غالباً ما تكون هناك حاجة للسرعة في مواجهة تحديات اليوم (أ. د لطفی کمال عزاز، 2022).

يلقي البحث الضوء على شكل جديد من أشكال رسم خرائط مخاطر الفيضانات، التي تساعد متخذي القرارات على تحديد المناطق الأكثر عرضة، وأخذ الاحتياطات اللازمة لمواجهة هذا النوع من الكوارث الطبيعية، يجمع هذا الشكل بين تقنيات التعلم الآلي ML ونظم المعلومات الجغرافية GIS، ومن أجل إبراز مدى أهمية هذا البحث قمنا بدراسة حالة مدينة المسيلة، التي تعد من بين أكثر المناطق عرضة للفيضانات.

توصلت هذه الدراسة إلى رسم خريطة المناطق المعرضة للفيضانات وذلك اعتماداً على المنهجية المذكورة سابقاً حيث تم المقارنة بين 3 خوارزميات تعلم آلة - نموذج xGBoost - خوارزمية الغابة العشوائية Random Forest - وخوارزمية الجار الأقرب K Nearest Neighbor - أعطت كل من هذه الخوارزميات دقة وهي على التوالي 97.92 - 95 - 93,75 ، تم الاعتماد في عملية رسم خريطة المناطق المعرضة للفيضانات على النموذج الأول والذي أعطى أكبر دقة xGBoost.

1. الطريقة والأدوات:

يستخدم علماء البيانات ومتخذي القرارات، الذكاء الاصطناعي AI ونظم المعلومات الجغرافية GIS في العقود الأخيرة، لتغيير الطرق التقليدية في وضع استراتيجيات وخطط المواجهة والتخفيف من شدة الأخطار الطبيعية، لما أثبتته هذه التقنيات من سرعة وكفاءة في تحليل البيانات والوصول إلى قرارات سليمة بدرجة معينة، ومن أجل الوصول إلى نتائج فعالة سنعتمد في ورقتنا هذه على نظم المعلومات الجغرافية GIS، والاستشعار عن بعد RS، جنباً إلى جنب مع أساليب تعلم الآلة ML، الذي يمكن تصنيفه ضمن فروع الذكاء الاصطناعي AI، لما يوفره من قدرات هائلة لدعم محلي البيانات المكانية وصناع القرار في الاستفادة من كميات البيانات الكبيرة التي أنتجتها أعداد متزايدة من أجهزة الاستشعار وتقنيات جمع البيانات (أ. د لطفی کمال عزاز، 2022) ، من أجل رسم خريطة المناطق المعرضة للفيضانات في مدينة المسيلة.


2. منطقة الدراسة:

تقع مدينة المسيلة في الجهة الشمالية الغربية لحوض شط الحضنة، ضمن بلدية المسيلة، يحدها:

- شمالاً: التجمع الثانوي "بوخميسة"
- شرقاً: بلدية المطارفة
- جنوباً: قرية غزال، والتجمع الثانوي مزريز
- غرباً: بلدية أولاد منصور

وهي نقطة تقاطع لكل من الطريق الوطني رقم 40، والطريق الوطني رقم 45، إضافة إلى الطريق الوطني رقم 60 الرابط بين حمام الضلعة غرباً ومركز المدينة، تقدر مساحة مجال الدراسة ب 49.17 كم²، يشغله حوالي 132975 نسمة حسب تعداد 2008.

الخريطة رقم (01): موقع منطقة الدراسة



المصدر: من إعداد الباحث باستخدام برنامج ARCGIS 10.8

3. مراحل إعداد البحث وخطواته:


غالبًا ما يتم تقسيم أساليب التعلم الآلي ML إلى مرحلتين (د . علاء طعيمة، 2022):

أ- **التعليم:** نموذج يحقق التعلم باستخدام مجموعات البيانات التعليمية.

ب- **التطبيق:** يستخدم النموذج المدرب لاتخاذ القرارات والتنبؤات على بعض البيانات التجريبية (التي لم يلاحظها النموذج في عملية التدريب).

في هذه الدراسة سنتبع نفس المراحل مع عملية انتقال بين التقنيتين (نظم المعلومات الجغرافية، وتعلم الآلة) من أجل تحديد إذا ما كانت المنطقة معرضة لخطر الفيضانات أم لا، حيث سنعمل على نظم المعلومات الجغرافية GIS في عملية جمع البيانات المكانية المتعلقة بالظاهرة، ثم استخدام هذه البيانات في تغذية نموذج تعلم الآلة ML وتدريبه، واختباره ثم تطبيقه عن طريق إعادة تزويده ببيانات لم يلاحظها من قبل لأجل عملية التنبؤ، لننتقل أخيرًا إلى عملية رسم خريطة المناطق المعرضة للفيضانات باستخدام نظم المعلومات الجغرافية اعتمادًا على البيانات المتنبئ بها عن طريق نموذج تعلم الآلة، وتحقيق الهدف المطلوب.

الشكل رقم (01): ملخص طريقة البحث وأدواته



المصدر: من إعداد الباحث 2023

1.3 المرحلة الأولى: التعلیم


يعبر مصطلح تعلم الآلة عن عملية تصميم برامج تستطيع التعلم من الخبرات السابقة، بحيث يتم تصميم وتطوير الخوارزميات والتقنيات التي تمكن الحاسب من امتلاك خاصية "التعلم" (عبد الرحمان عثمان، 2018)، تشمل هذه العملية مجموعة من الخطوات الفرعية المتسلسلة، بدءاً من جمع البيانات اللازمة لتغذية النموذج، مروراً بفحص وتحضير هذه البيانات، ثم اختيار الخوارزمية المناسبة للتدريب، وصولاً إلى عملية اختبار هذا الأخير، وفيما يلي شرح لأهم الخطوات المتبعة في هذه الدراسة:

1.1.3 الخطوة الأولى: جمع البيانات

بعد تحديد الهدف من تصميم نماذج تعلم الآلة، يتم تحديد البيانات اللازمة ومصادر الحصول عليها وتوفيرها، اعتمدنا في هذه الدراسة على نظم المعلومات الجغرافية GIS، في إنشاء وتصميم قاعدة بيانات جغرافية مكانية، خاصة بالمجال المدروس، وبمعايير ترتبط بظاهرة الفيضانات، يتم الاعتماد عليها فيما بعد من أجل تغذية نموذج تعلم الآلة ML وتدريبه، كما قمنا بتقسيم هذه الخطوة إلى جزأين أساسيين:

أ- الجزء الأول: تتبع حدوث الظاهرة تاريخياً في منطقة الدراسة، فمدينة المسيلة من المناطق الأكثر عرضة لخطر الفيضانات، ويعتبر فيضان 1994، وفيضان سبتمبر 2007 من أكبر الفيضانات التي شهدتها المدينة، والذي خلف 20 قتيل وأكثر من 200 مليار سنتيم من الخسائر المادية (هاجر إبراهيمي وآخرون، 2021)، في هذا البحث تم الاعتماد على المعلومات التي زودتنا بها مديرية الحماية المدنية لولاية المسيلة، إضافة إلى الاطلاع على بعض الدراسات السابقة، ثم التأكد من هذه المعلومات باستخدام بيانات الأقمار الصناعية، والخريطة رقم (02) توضح بعض المناطق التي تعرضت سابقاً لعدة فيضانات، يتم تحديد مجموعة من العينات كطبقة نقطية point داخل برامج نظم المعلومات الجغرافية GIS، حيث تم أخذ 315 عينة منها 140 نقطة لم يحدث بها فيضان، و 175 نقطة حدث بها فيضان.

الخريطة رقم (02): آثار بعض الفيضانات بمدينة المسيلة



المصدر: من إعداد الباحث باستخدام برنامج ARCGIS 10.8



صورة (02): حتى 5 جويلية، 2015



صورة (01): حتى 500 مسكن، 2007



صورة (04): حي 50 مسكن، أكتوبر 2022



صورة (03): بالقرب من مقر الولاية، 2021

ب- الجزء الثاني: تحديد وجمع البيانات المكانية حول العوامل المسببة لظاهرة الفيضانات: حيث أن هذه الأخيرة تحدث نتيجة لعدة أسباب منها هطول أمطار غزيرة لفترة زمنية طويلة، وارتفاع منسوب الأنهار والبحيرات (أ.د. جمال باقر مطلق، العدد 27)، إضافة لعامل انحدار السطح الذي يؤدي إلى اكتساب أحواض التصريف خصائص هيدرولوجية تصنف بدرجات خطرة في حال الانحدارات الشديدة، نتيجة سرعة توليد الجريان وعدم الاتاحة بنفاذ المياه نحو الطبقات تحت السطحية، كما أن الخطورة قائمة أيضا في حال الانحدارات الضعيفة نتيجة تجمع المياه المنحدرة إليها من النطاقات الأخرى (صهيب حسن خضر ، 2021)، دون أن نغفل عن الدور الرئيسي يؤديه ارتفاع سطح الأرض المقام عليها المناطق العمرانية في حدوث الفيضانات (رنا نسيم جورانه وآخرون، 2017)، في هذه الدراسة يتم تمثيل العوامل السابق ذكرها في شكل طبقات Raster داخل برامج نظم المعلومات الجغرافية GIS ، من أجل تسهيل عملية استخراج قيم هذه العوامل بواسطة الطبقة النقطية التي تم إنشاؤها في الجزء الأول، لنصل بذلك إلى تصميم قاعدة بيانات يمكن بواسطتها تغذية نموذج تعلم الآلة.

الجدول (01): العوامل ومصادر البيانات التي تم الاعتماد عليها في الدراسة


العامل	البيانات المستخدمة	مصدر البيانات
الارتفاعات	نموذج ارتفاعات رقمي بدقة 30 متر	/https://earthexplorer.usgs.gov
الانحدارات	نموذج ارتفاعات رقمي بدقة 30 متر	/https://earthexplorer.usgs.gov + المعالجة الشخصية من طرف الباحث
التساقط	طبقة من نوع Raster يتم اشتقاقها interpolation من بيانات التساقط ل 12 محطة لمدة 39 سنة	https://power.larc.nasa.gov/data-access-viewer/ + المعالجة الشخصية من طرف الباحث
المسافة من الأودية	طبقة من نوع Raster يتم استخراجها بواسطة أداة المسافة الإقليدية، تستخدم طبقة الأودية كمدخل.	Open Street Map + المعالجة الشخصية من طرف الباحث
استخدامات الأرض	طبقة من نوع Raster، مصنفة من طرف شركة ESRI	ESRI LandUse 2021

المصدر: من إعداد الباحث 2023

بعد عملية جمع البيانات باستخدام برنامج نظم المعلومات الجغرافية ARCGIS وتكوين قاعدة البيانات نقوم بتصديرها على شكل ملف csv file، يتم استخدامه في المرحلة القادمة التي تعتمد على تقنيات تعلم الآلة ML باستخدام لغة برمجة python وبعض مكتباتها، حيث توفر هذه

الأخيرة مجموعة خوارزميات برمجية مستقلة تساعد في إيجاد حلول أكثر كفاءة وأكثر دقة، أي أننا سنتبع طريقة جديدة تعتمد على مجموعة بيانات يمكن من خلالها التوصل إلى قرار دون الحاجة إلى التدخل البشري.

الخريطة رقم (03): العوامل التي تم الاعتماد عليها في الدراسة



المصدر: من إعداد الباحث باستخدام برنامج ARCGIS 10.8

2.1.3 الخطوة الثانية: تحضير البيانات

تتمثل أولى خطوات تصميم نماذج تعلم الآلة بعد عملية جمع البيانات في قراءة هذه الأخيرة وتحضيرها، أي الاطلاع على شكل البيانات وفحصها والتأكد من عدم وجود قيم مفقودة أو مكررة، حيث توفر لغة برمجة بايثون مجموعة من المكتبات والأوامر التي تساعد في هذه العملية.

```
df = pd.read_csv("flood data.csv")
df.head(4)
```

	elevation	Precipitation	Slope	Distance_Rivers	Land_Use	flood
0	478	251.917	2.08627	1416.05	urban area	1
1	476	251.900	2.72401	1392.01	barren lands	1
2	476	251.900	2.72401	1392.01	barren lands	1
3	475	251.900	0.80035	1392.01	barren lands	1

صورة (06): قراءة البيانات باستخدام لغة برمجة python

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 315 entries, 0 to 314
Data columns (total 6 columns):
#   Column          Non-Null Count  Dtype
---  ---
0   elevation        315 non-null    int64
1   Precipitation    315 non-null    float64
2   Slope            315 non-null    float64
3   Distance_Rivers  315 non-null    float64
4   Land_Use         315 non-null    object
5   flood            315 non-null    int64
dtypes: float64(3), int64(2), object(1)
memory usage: 14.9+ KB
```

صورة (05): الاطلاع على شكل البيانات، نوعها

والتأكد من عدم وجود قيم مفقودة

غالباً ما يكون شكل البيانات التي تم جمعها غير منظم، أو تحتوي على عناصر مكررة أو مفقودة، يتم إعادة تنظيمها أو حذف القيم المكررة أو تعويض العناصر المفقودة بقيم معينة حسب البحث وأهمية تلك العناصر وتسمى هذه العملية بمرحلة المعالجة الأولية preprocessing.

3.1.3 الخطوة الثالثة: بناء النموذج

غالباً ما يتم تقسيم مهام التعلم الآلي إلى ثلاثة فئات رئيسية (Neeraj Kumar & Sharma Diksha, 2017):

- التعلم تحت الإشراف Supervised Learning


- التعلم بدون إشراف Unsupervised Learning

- تعلم التعزيز Reinforcement Learning

يتم تحديد نوع مهمة التعلم الآلي بناءً على الهدف من تصميم النموذج والبيانات المتوفرة، حيث يمكن تصنيف موضوع هذه الدراسة ضمن مهمة التعلم الخاضع للإشراف Supervised Learning، أين يتم تغذية مجموعة من عينات التدريب للخوارزمية بالإجابات الصحيحة (الأهداف، في هذه الدراسة الهدف هو هل تعرضت العينة للفيضانات سابقاً أم لم تتعرض)، ويكون لدينا بيانات إدخال أولية ونتائجها، فتحاول الخوارزمية تعلم دالة بناءً على هذه البيانات والإجابات الصحيحة، لتكون قادرة على التنبؤ بدقة بالقيم المستهدفة للعينات الجديدة (د. علاء طعيمة، 2022)، وتنقسم مهمة التعلم الخاضع للإشراف إلى نوعين رئيسيين هما (محمد الحلاح، 2020):

- التصنيف Classification: التنبؤ بصنف كائن معين (وهو النوع الذي يعتمد عليه موضوع هذه الورقة البحثية).
- الانحدار Regression: التنبؤ بنقطة معينة على محور رقمي.

الشكل رقم (02): تصنيف موضوع الدراسة ضمن فئات مهام تعلم الآلة



المصدر: من إعداد الباحث 2023

تتم عملية تصنيف الكائنات أو الأشياء بناءً على وجود ميزات معينة Features، فاحتمالية تعرض عينة معينة للفيضانات من عدمه يرتبط بمجموعة العوامل التي تم تحديدها خلال مرحلة جمع البيانات (التساقط، الارتفاعات، الانحدارات، المسافة للأودية، واستخدامات الأرض).

صورة (07): الهدف والميزات في مهمة تعلم الآلة تحت الإشراف

الميزات						الهدف
<pre>df = pd.read_csv("flood df.head(4)</pre>						
	elevation	Precipitation	Slope	Distance_Rivers	Land_Use	flood
0	478	251.917	2.08627	1416.05	urban area	1
1	476	251.900	2.72401	1392.01	barren lands	1
2	476	251.900	2.72401	1392.01	barren lands	1
3	475	251.900	0.80035	1392.01	barren lands	1

المصدر: من إعداد الباحث 2023

بعد ذلك يأتي دور تحديد الخوارزمية المناسبة لتدريب النموذج، كما يمكن المقارنة بين عدة خوارزميات، في بحثنا هذا تم تقييم نتائج ثلاثة خوارزميات، خوارزمية الغابة العشوائية Forest Rando التي تعتمد على إنشاء أشجار القرار وآلية التصويت في عملية التنبؤ، وخوارزمية أقرب جار Neighbor Nearest-K التي تعتمد على مقياس التشابه و المسافة، وخوارزمية تعزيز التدرج الشديد XGBoost التي تتميز بسرعة التدريب وإمكانية موازنته وتوزيعه على مجموعات. (الأمين عبد الله الامين طه وآخرون، 2022)

4.1.3 الخطوة الرابعة: التدريب والاختبار

يتم في هذه المرحلة تقسيم البيانات إلى عينات تدريب وعينات اختبار، تم استخدام 85 % من إجمالي البيانات كعينات تدريب والباقي للاختبار في دراستنا هذه، وتم تقييم أداء النموذج واختباره باستخدام أربعة مقاييس للأداء (د , علاء طعيمة، 2022):

- **دقة التصنيف Accuracy:** وهي عدد تنبؤات التصنيف الصحيحة مقسوماً على العدد الإجمالي للتنبؤات.
- **الحساسية Precision:** هو عدد النتائج الإيجابية الصحيحة مقسوماً على عدد النتائج الإيجابية التي تنبأ بها المصنف، يقيس مدى جودة النموذج عندما يكون التوقع إيجابياً.
- **الاسترجاع Recall:** وهو مقياس لنماذج التصنيف، يجب على السؤال: عندما كانت الحقيقة الأساسية هي الفئة الإيجابية، ماهي النسبة المتوقعة للتنبؤات التي حددها النموذج بشكل صحيح على أنها فئة إيجابية.
- **F1 Score:** يجمع مقياس التقييم درجة F بين الحساسية Precision والاسترجاع Recall، كمقياس لفعالية التصنيف.

2.3 المرحلة الثانية: التطبيق

إن الهدف الأساسي من بناء نماذج تعلم الآلة، هو الاستفادة منها لاحقاً للقيام ببعض المهام كالتنبؤ أو التصنيف أو التجميع، في دراستنا هذه تمت المقارنة بين نتائج ثلاثة خوارزميات، والاعتماد على النموذج الذي يعطي أعلى دقة، والاستفادة منه في تصنيف مجموعة من النقاط الجديدة إلى نقاط معرضة للفيضانات وأخرى غير معرضة.

4. النتائج ومناقشتها:

1.4 اختبار دقة النموذج:

في هذه الدراسة تم الاعتماد على مقاييس الأداء سابقة الذكر، وكانت نتائج تقييم النماذج حسب الخوارزميات المستعملة كما يلي:


الجدول رقم(02): نتائج مقاييس أداء الخوارزميات المستعملة في الدراسة

الخوارزمية	Accuracy (%)	precision	recall	F1 score
XGboost	97.92	1.0	0.9714	0.9855
Random Forest	95.83	1.0	0.9259	0.9615
K Nearest Neighbor	93.75	0.931	0.9643	0.9474

المصدر: من إعداد الباحث 2023

2.4 التطبيق:

تم الاعتماد على نموذج XGboost، والذي أعطى أعلى دقة في معظم مقاييس الأداء، و تم أيضا تطبيق اختبار roc_curve و AUC للتأكد أكثر من دقة هذا النموذج وإثبات عدم وجود حالات التحيز والتدريب المفرط للنموذج.



المصدر: من إعداد الباحث 2023

وبعد التأكد من دقة هذا النموذج بمعظم أنواع الاختبار والتقييم، تتم عملية تطبيقه اعتمادا على مجموعة بيانات جديدة يتم الحصول عليها باستخدام برامج نظم المعلومات الجغرافية، تحمل هذه البيانات الخصائص المعلومة (الميزات فقط كالانحدارات، الارتفاعات، كمية التساقط، المسافة من الاودية، استخدامات الأرض)، كما تحمل معلومات جغرافية عن كل نقطة، حيث يكون هذا النموذج قادرا على تصنيف البيانات الجديدة إلى نقاط معرضة لخطر الفيضانات وأخرى غير معرضة.

الصورة رقم (08): استخدام النموذج

	elevation	Precipitation	Slope	Distance_Rivers	Land_Use	POINT_X	POINT_Y	Target
0	448	263.944	1.92689	180.0	barren lands	637231.4777	3.948284e+06	0
1	447	263.902	1.13179	150.0	barren lands	637261.4777	3.948284e+06	0
2	447	263.861	1.47554	120.0	barren lands	637291.4777	3.948284e+06	0
3	446	263.820	2.88345	90.0	barren lands	637321.4777	3.948284e+06	0
4	445	263.780	2.50405	60.0	barren lands	637351.4777	3.948284e+06	0
...	...	...	...	...	...	...	...	...
54319	503	273.088	2.86122	390.0	barren lands	640321.4777	3.956684e+06	1
54320	504	273.164	1.82458	360.0	barren lands	640351.4777	3.956684e+06	0
54321	504	273.242	0.35795	330.0	vegetation	640381.4777	3.956684e+06	0
54322	504	273.321	0.80035	300.0	barren lands	640411.4777	3.956684e+06	0
54323	504	273.401	1.07372	270.0	barren lands	640441.4777	3.956684e+06	0


54324 rows × 8 columns

الميزات الاحداثيات القيم المتنبئ بها

المصدر/ من إعداد الباحث 2023

أخيراً نقوم بتصدير البيانات لبرنامج نظم المعلومات الجغرافية، ونستخدم النقاط المنتبى بها في تمثيل المناطق المعرضة للفيضانات والمناطق غير المعرضة، كما يمكن تحويل الطبقة النقطية point إلى طبقة مساحية polygon أو شبكية Raster، من أجل تمثيل الظاهرة بشكل أفضل.

الخريطة رقم (04): نتيجة تطبيق النموذج في منطقة الدراسة لتحديد المناطق المعرضة للفيضانات



المصدر: من إعداد الباحث باستخدام برنامج ARCGIS 10.8

الخلاصة:

تعد تقنيات التعلم الآلي ML ونظم المعلومات الجغرافية من بين الأساليب الحديثة القادرة على حماية الناس والممتلكات إذا ما تم استغلالها بطريقة صحيحة، حيث يمكن دمج هذه التقنيات للاستفادة منها في بناء أنظمة الإنذار المبكر وتحديد المناطق التي قد تتأثر بالكوارث الطبيعية، جاءت هذه الدراسة من أجل التأكيد على ذلك من خلال إلقاء الضوء على أهمية استخدامها في رسم خريطة المناطق المعرضة للفيضانات بمدينة المسيلة، أين تم تقييم ومقارنة دقة نتائج 3 أنواع من خوارزميات تعلم الآلة ML، أعطى نموذج xgboost أعلى دقة، تم تطبيقه والاستفادة منه في عملية تحديد احتمالية تعرض أو عدم تعرض مجموعة كبيرة من النقاط الجغرافية التي تحمل خصائص مكانية معينة، والتي جعلت من عملية رسم خريطة المناطق المعرضة للفيضانات أمراً ممكنًا داخل برامج نظم المعلومات الجغرافية.

الإحالات والمراجع:

1. طعيمة ع. (2022). معجم مصطلحات التعلم الآلي والتعلم العميق وعلوم البيانات. العراق: جامعة القادسية.
2. طعيمة ع. (2022). تعلم الآلة وعلوم البيانات (كلية علوم الحاسوب وتكنولوجيا المعلومات). العراق: جامعة القادسية.
3. مطلق ج.، & الجزائري ح. م. (2018). إدارة كوارث الفيضانات والسيول في منطقة بحر النجف. مجلة البحوث الجغرافية، 2(27)، 37-64.
4. لالح م. (2020). مدخل إلى الذكاء الاصطناعي وتعلم الآلة. أكاديمية حاسوب.

5. عراز ل. ك. (2022). الاتجاهات الحديثة والمستقبلية في نظم المعلومات الجغرافية. مجلة بحوث كلية الآداب، جامعة المنوفية، 33(131)، 3-35.
<https://doi.org/https://doi.org/10.21608/sjam.2022.158351.1686>
6. الامين عبدالله طه ا.، مرتضى مالك ادم ا.، & عاطف معاوية ا. (2022). بناء نموذج ذات خوارزميات تجميعية مستقر للتنبؤ بمعدلات هطول الامطار بدقة في تنقيب البيانات بدولة السودان. مجلة العلوم الانسانية والطبيعية، 3(9)، 94-114.
<https://doi.org/https://doi.org/10.53796/hnsj397>
7. جوارنة ر. ن.، & المشايخي س. ب. س. ب. س. (2018). دور الخصائص الطبيعية في زيادة قابلية تعرض المناطق العمرانية في محافظة مسقط للفيضانات خلال الفترة (2007-2015) باستخدام نظم المعلومات الجغرافية. مجلة كلية الاداب والعلوم الاجتماعية، 9(1)، 65-78.
8. صهيب ح. خ. (2021). تقييم مخاطر الفيضان لحوض كارديم حسب طريقة تحليل متعدد المتغيرات. مجلة أبحاث كلية التربية الأساسية، 17(4)، 886-915.
9. إبراهيمي ه.، & عميرش ح. (2021). دراسة حساسية مدينة المسيلة لخطر الفيضانات ، باستعمال نظم المعلومات الجغرافية. مجلة العلوم الانسانية جامعة قسنطينة 1، 32(2)، 211-232.
10. واتكينز ك.، & اخرون م. ت. ا. ا. (2007). تقرير التنمية البشرية 2007/2008 محاربة تغير المناخ: التضامن الإنساني في عالم منقسم (ص 1-388). استرجع في من برنامج الامم المتحدة الانمائي website:
https://static.un.org/ar/esa/hdr/pdf/hdr0708/HDR_20072008_Complete.pdf
11. عثمان ع. ا. (2019، يوليو 25). مقدمة عن تعلم الآلة. استرجع في 14 يونيو، 2022، من
<https://solarinarabic.blogspot.com/2019/07/blog-post.html>
12. منظمة الصحة ا. الفيضانات. استرجع في 19 يناير، 2022، من
https://www.who.int/ar/health-topics/floods#tab=tab_1
13. Mosavi, A., Ozturk, P., & Chau, K.- wing. (2018). Flood Prediction Using Machine Learning Models: Literature Review. *Water*, 10(11).
<https://doi.org/https://doi.org/10.3390/w10111536>
14. Sharma, D., & Kumar, N. (2017). A review on machine learning algorithms, tasks and applications. *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 6(10).