



Volume 7, Issue 8, August 2020, p. 276-291

Istanbul / Türkiye

Article Information

*Article Type: Research Article*

*This article was checked by iThenticate.*

Doi Number :<http://dx.doi.org/10.17121/ressjournal.2774>

Article History:

**Received**

10/07/2020

**Received in revised form**

20/07/2020

**Available online**

15/08/2020

## APPLICATIONS OF ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN NATURAL DISASTER RISKS MANAGEMENT

Imane BOUGUERRA<sup>1</sup>

Hadj Moussa MANSOURI<sup>2</sup>

### Abstract

This study aimed to identify the method of using artificial intelligence and machine learning to protect people from the effects of natural disaster risks, The descriptive approach was followed to achieve this goal. The data (from international Bank's data, and of Global Facility for Disaster Reduction and Recovery' data), were collected to collect the necessary information and statistics. This research revealed through case studies that the machine learning for disaster risks management often applied to methods used in the classification of remotely sensed satellites, and from seismic sensor data networks and building inspection records to social media posts. Research has also shown that careful identification of vulnerability is one of the foundations for more effective risk management, And that the use of machine learning algorithms can significantly reduce the costs of natural disaster risk management.

**Keywords:** Artificial Intelligence, Machine Learning, Risks, Natural Disaster Management.

<sup>1</sup> Dr, Ghardaia University (UN4701), Algeria, bouguerra.Imane@univ-ghardaia.dz

<sup>2</sup>Dr, University Center Tamanrasset, Algeria, mansouri.hm@cu-tamanrasset.dz

## تطبيقات الذكاء الاصطناعي و التعليم الآلي في إدارة مخاطر الكوارث الطبيعية

إيمان بوقرة<sup>3</sup>  
حاج موسى منصوري<sup>4</sup>

### الملخص

هدفت هذه الدراسة إلى التعرف على كيفية استخدام الذكاء الاصطناعي والتعليم الآلي لحماية الناس من آثار مخاطر الكوارث الطبيعية، ولتحقيق هذه الغاية تم اتباع المنهج الوصفي، ولقد تم الاعتماد على بيانات البنك الدولي و الصندوق العالمي للحد من الكوارث والتعافي من آثارها و ذلك لجمع المعلومات و الاحصائيات اللازمة. كشف هذا البحث من خلال دراسات الحالة الذي تطرق إليها أن التعلم الآلي لإدارة مخاطر الكوارث الطبيعية في الغالب ينطبق على الطرق المستخدمة في تصنيف الأقمار الصناعية المستشعرة عن بعد والجوي وطائرة بدون طيار وحتى على التصوير على مستوى الشارع، و شبكات بيانات الاستشعار الزلزالية وبناء سجلات التفتيش إلى منشورات التواصل الاجتماعي. كما بين البحث أن ويُعد التحديد الدقيق لمواقع التعرض للخطر أحد الأسس اللازمة لتحقيق إدارة أكثر فاعلية لمخاطر الكوارث، و أن استخدام خوارزميات التعلم الآلي يمكن تقليص تكاليف عملية إدارة مخاطر الكوارث الطبيعية بدرجة كبيرة.

**الكلمات المفتاحية:** تطبيقات، ذكاء اصطناعي، تعليم آلي، مخاطر، إدارة، كوارث طبيعية.

### المقدمة:

على مدار العقد الماضي، برز الدور الرائد الذي اضطلع به البنك الدولي على الصعيد العالمي في إدارة مخاطر الكوارث بدعمه للبلدان في تقييم مدى التعرض لمخاطر الكوارث ومواجهتها، بحيث ألحقت الكوارث بالفقراء والضعفاء أكبر الضرر، ففي الفترة بين عامي 1995 و 2014، بلغت نسبة الوفيات الناتجة عن العواصف 89% في البلدان ذات الدخل المنخفض بالرغم من أن نسبة العواصف التي شهدتها هذه البلدان لم تتجاوز 26%. ولقد وأدت الكوارث الطبيعية على مدار الثلاثين عامًا الماضية، إلى فقد ما يزيد على 2.5 مليون شخص ونحو 4 تريليونات دولار، حيث تضاعفت الخسائر العالمية من 50 مليار دولار سنويًا في الثمانينيات إلى 200 مليون دولار خلال العقد الأخير. وجاء عام 2017 ليدق ناقوس الخطر في هذا الشأن، إذ بلغت خسائر العالم 330 مليار دولار نتيجة كوارث طبيعية مدمرة (WWW.ALBANKALDAWLI.ORG,2019)

و مع اتجاهات النمو السكاني المتزايد، والتوسع الحضري، والتوقعات المناخية للطقس الأكثر تواتراً وشدة، فإن المزيد من الأشخاص والأصول معرضون لخطر الأخطار الطبيعية. تحتاج المجتمعات والحكومات إلى التفكير بشكل خلاق وإيجاد طرق جديدة لبناء المرونة، ويمكن لبعض التطورات الأخيرة في العلوم والتكنولوجيا توفير حلول واعدة.

<sup>3</sup>د.، جامعة غرداية (UN4701)، الجزائر، [bouguerra.Imane@univ-ghardaia.dz](mailto:bouguerra.Imane@univ-ghardaia.dz)

<sup>4</sup>د.، المركز الجامعي تامنغست، الجزائر، [mansouri.hm@cu-tamanrasset.dz](mailto:mansouri.hm@cu-tamanrasset.dz)

و من بين تلك الحلول الواعدة ما يسمى بالذكاء الاصطناعي والتعلم الآلي الذي أصبح من التعبيرات الدارجة الطنّانة في الأعوام القليلة الماضية، و تستند هذه الأساليب من علوم الكمبيوتر إلى الإحصاء وتستخدم في تدقيق البيانات وفرزها والتصرف بناء عليها. وتعمل أساليب التعلم الآلي هذا في برامج أو خوارزميات تكرارية تتعلم من مدخلات البيانات من أجل تحسين النتائج اللاحقة. وأصبحت خوارزميات التعلم الآلي بالفعل ركيزة تشغيل شبكة الإنترنت: في المتاجر الإلكترونية، ومحركات البحث، والإعلانات الموجهة، والمعلومات المنشورة على وسائل التواصل الاجتماعي.

تقدم هذه الورقة البحثية اتجاهات جديدة للذكاء الاصطناعي والتعليم الآلي التي من شأنها أن يوفر طرقاً جديدة لفحص تلك الأمور المعقدة العلاقات وتقديم إجابات أكثر دقة وكفاءة ومفيدة.

### 1. الإشكالية:

يتضح التساؤل الرئيسي لهذه الورقة البحثية على ضوء ما تم سرده من احصائيات، فيما يلي: كيف يتم تسخير الذكاء الاصطناعي والتعليم الآلي لحماية الناس من آثار مخاطر الكوارث الطبيعية؟

2. أسئلة البحث: و تتمثل فيما يلي:

- ما المقصود بالكوارث الطبيعية و ماهي التدابير المتعلقة بإدارتها؟
- ما الفرق بين الذكاء الاصطناعي و التعليم الآلي، و ما أنواع هذا الأخير؟
- ماهي مراحل إدارة مخاطر الكوارث الطبيعية باستخدام التعليم الآلي؟

### 3. الأهمية والأهداف:

يستمد هذا البحث أهميته من كونه يعتبر مرجعية مفيدة وموجزة ومزيلة للغموض يمكن للقراء، من: مديري المشاريع و المشتغلين بإدارة مخاطر الكوارث في هذا المجال و المتخصصين ببيانات المخاطر البيانات أو أي شخص آخر مهتم بهذا المجال من مجالات علوم الكمبيوتر، بحيث يمكنهم استخدامها من فهم أفضل لكيفية تطبيق التعلم الآلي في مشاريع إدارة مخاطر الكوارث.

لذلك، تهدف هذه الورقة البحثية إلى التركيز قدر الإمكان، وتوفير المعلومات الأساسية ودراسات الحالة الخاصة بإدارة مخاطر الكوارث.

4. هيكل البحث: للإجابة عن الإشكالية الرئيسية، نقسم هذه الورقة البحثية إلى المحاور التالية:

- المحور الأول: الكارثة وإدارة الكوارث.
- المحور الثاني: الذكاء الاصطناعي و التعليم الآلي.
- المحور الثالث: دراسات حالة في إدارة مخاطر الكوارث.

### المحور الأول: الكارثة و إدارة الكوارث:

#### أولاً: الكارثة (تعريفها و أقسامها):

أ. تعريف الكارثة: عرف دليل الدفاع المدني الصناعي: الكارثة بأنها حادثة كبيرة ينجم عنها خسائر جسيمة في الأرواح و الممتلكات و قد تكون كارثة طبيعية **NATURAL DISASTER** مردها فعل الطبيعية (فيضانات، زلازل، عواصف...الخ) و قد تكون كارثة فنية **TECHNICAL DISASTER** مردها فعل الانسان سواء كان إيرادياً (عمداً) أم لا إيرادياً (بالإهمال) و تتطلب مواجهتها معونة الأجهزة الوطنية كافة (حكومية و أهلية) أو الدولية إذا كانت قدرة مواجهتها تفوق القدرات الوطنية (www.isdm.gov, 2019).

و لقد حدد مكتب الولايات المتحدة للمساعدات الأجنبية مؤشرات لما يمكن اعتباره كارثة، على النحو التالي (الزبير، 2016):

- في حالة موت 6 أفراد على الأقل نتيجة لوقوع زلزال.
- إذا كان اجمالي الوفيات و الجرحى بلغ كحد أدنى 25 حالة.
- إذا كان عدد المتضررين من الحدث بأي شكل يبلغ 1000 حالة.

و يمكن التفريق بين الكارثة و الأزمة، حيث أن الأزمة خلل مفاجئ نتيجة لأوضاع غير مستقرة يترتب عليها تطورات غير متوقعة نتيجة عدم القدرة على احتوائها من قبل الأطراف المعنية، و غالباً ما تكون الانسان، و يتجلى الفارق الجوهرى بين الكارثة و الأزمة، في عنصر التنبؤ أو التوقع الذي يكاد أن يكون مستحيلاً بالنسبة للكارثة في حين يكون ممكناً بالنسبة للأزمة (غنيومات، 2009).

ب. أقسام الكوارث: و تنقسم الكوارث إلى قسمين رئيسيين، هما (غنيومات، 2009):

❖ القسم الأول: الكوارث الطبيعية: و هي الكوارث التي تكون سببها الطبيعة منفردة دونما أي تدخل للإنسان، و يندرج تحت هذا الاسم الأنواع التالية:

- جيولوجية و جيومورفولوجية و مناخية: و هي تشمل على: الزلازل، البراكين، تحرك المواد على جوانب المنحدرات، الهبوط الأرضي، تآكل و نحر السواحل، الانهيارات الجليدية، السيول، الفيضانات، العواصف و الزوابع و الأعاصير الثلجية، موجات الحر و البرد، الصقيع، التصحر، الجفاف و المجاعات، حرائق الغابات.
- كونية: تساقط الشهب و النيازك، الاشعاع الكوني.
- بيولوجية: أوبئة كإنفلونزا الطيور و الخنازير، الجراد و الآفات الزراعية، الحشرات البيئية، تدمير الغطاء النباتي، تعرية التربة.

❖ القسم الثاني: كوارث بشرية: و هي التي تكون من صنع الانسان، إما بغير إرادته، أو بإرادته و تخطيطه، و يمكن تفصيل أنواعها على النحو الآتي:

- غير إرادية: و هي مثل تلوث الهواء و التربة، التلوث الضوئي و البصري، الحرائق، التلوث الاشعاعي، انهيار المنشآت، حوادث المرور، حوادث الصناعة، التلوث البترولي.
- إرادية و مخططة: الحروب، النهب و السلب، جرائم التخريب، أسلحة الدمار الشامل، (جودة، 1998) الأمراض الفتاكة كالإيدز.

ثانياً: إدارة مخاطر الكوارث (مفهومها و التدابير المتعلقة بها):

أ. مفهوم إدارة مخاطر الكوارث: يعرف بأنه نشاط هادف يقوم به المجتمع لتفهم طبيعة المخاطر لكي يحدد ما ينبغي عمله إزاءها و اتخاذ التدابير للتحكم في مواجهة الكوارث و تخفيض حدتها و آثارها و ما يترتب عليها، و يتصل هذا النشاط بعاملين هما الإدراك و التحكم (الزبير، 2016):

- الإدراك يعتمد على الامام بالمعلومات لتفهم حجم الخطر و تحديد وسائل المواجهة و تقييم المواقف،
- التحكم يتصل بتصميم و تنفيذ التدابير الهادفة لدرء أو تخفيف آثار الكارثة.

إن إدارة الكوارث عموماً تبنى على أساس اعتبارين أساسيين:

الاعتبار الأول: درء أخطار الكوارث إما بإزالة مسبباتها أو بإعداد التدابير اللازمة للحد من آثارها. الاعتبار الثاني: تصميم التنسيق التنظيمي الفعال الذي يمكن من التحكم لمواجهة الكارثة و تقليص أضرارها و العمل على إعادة التوازن في البيئة بعد إزالة الخطر (الطيب، 1992).

ب. التدابير المتعلقة بالكوارث: إن التنسيق لمواجهة الكوارث الطبيعية لا يقتصر على الدولة و حدها (التنسيق الإداري للدولة) و إنما يتعداها إلى القطاع الأهلي بكافة تخصصاته و إلى المواطنين كأفراد و جماعات، بل و إلى الجمعيات الخيرية و كافة مؤسسات المجتمع المدني، هذا فضلاً عن التنسيق مع المنظمات الاقليمية و الدولية، و يتم تحقيق التدابير المتعلقة بالكوارث على مرحلتين هما (غنيومات، 2009):

(1) التدابير الوقائية قبل وقوع الكارثة: لم يتمكن العلم الحالي من ارتقاب الكوارث الطبيعية على المدى القصير، إذ يمكن فقط التنبؤ بها على المدى المتوسط و البعيد، و نعني بهذا عدم معرفة التاريخ و الساعة و المكان الدقيق لوقوع الكارثة. رغم أن العلماء يسعون

حالياً لمحاولات ارتقَاب تستعمل تغيير مختلف الثوابت الفيزيائية عند اقتراب وقوع الكارثة، إلا أن هذه المحاولات لا زالت لم ترتق لمستوى النجاح الفعلي بسبب تعقد الكوارث الطبيعية. إلا أن المجتمعات تأخذ العديد من متطلبات السلامة العامة استعداداً للظروف الطارئة، وتتضمن التدابير الوقائية قبل وقوع الكارثة فيما يلي: التخطيط لمواجهة الكوارث - التدريب الميداني- فرض الضرائب - وضع صندوق للمحتاجين - التأمين ضد الكوارث.

(2) التدابير الاجرائية اثناء و بعد وقوع الكارثة: و تتمثل في: وظيفة الدولة - الدفاع المدني - السلامة الغذائية - اعمال الاغاثة و أحكامها.

### المحور الثاني: الذكاء الاصطناعي و التعليم الآلي:

أولاً: مفهوم الذكاء الاصطناعي: لمعرفة ماهية الذكاء الاصطناعي يتعين أولاً تحديد المقصود بالذكاء الانساني(أحمد، 2018):

- الذكاء الانساني: هو الذي يرتبط بالقدرات العقلية مثل القدرة على التكيف مع ظروف الحياة والاستفادة من التجارب والخبرات السابقة والتفكير والتحليل والتخطيط وحل المشاكل والاستنتاج السليم والاحساس بالآخرين، بالإضافة إلى سرعة التعلم واستخدام ما تم تعلمه بالشكل السليم والمفيد.
- الذكاء الاصطناعي: فهو محاكاة لذكاء الانسان وفهم طبيعته عن طريق عمل برامج للحاسب الآلي قادرة على محاكاة السلوك الانساني المتسم بالذكاء، ويوجد الذكاء الاصطناعي حالياً في كل مكان حولنا، بداية من السيارات ذاتية القيادة والطائرات المسيرة بدون طيار وبرمجيات الترجمة أو الاستثمار وغيرها الكثير من التطبيقات المنتشرة في الحياه.



يعتبر التعلم الآلي نوع أنواع الذكاء الاصطناعي، وقد كانت خوارزميات التعلم الآلي، وبعضها أكثر بساطة وتركيزاً من غيرها، جزءاً من علوم الحاسوب منذ أواخر الخمسينات من القرن الماضي. وانطلاقاً من رؤية الحاسوب، كانت خوارزميات رائده في مجالات مثل الاستشعار عن بعد بواسطة السواتل وتحليل البيانات الإحصائية. الآن هي المتحكمة في العديد من جوانب مختلفة من حياتنا الرقمية اليومية، من محركات البحث إلى التسوق عبر الإنترنت.

و لقد تأسس الذكاء الاصطناعي (الذكاء الاصطناعي) باعتباره تخصصاً أكاديمياً في 1956. علي الرغم من ان الذكاء الاصطناعي غالباً ما تستخدم كمرادف للتعلم الآلي، وهناك بعض الاختلافات الرئيسية التي تحتاج إلى توضيح، أصبحت الذكاء الاصطناعي مصطلحاً شاملاً يشمل جميع برامج التعلم الآلي وكذلك الذكاء الاصطناعي العام (ARTIFICIAL GENERAL INTELLIGENCE) (STRONG ARTIFICIAL INTELLIGENCE) الذي يشير إلى الإصدارات المستقبلية من أجهزه كمبيوتر الذكاء الاصطناعي المعقدة والمدركة للذات والتي لا يمكن تمييزها مع البشر عند اختبارها (GFDRR,2018) وهذه ليست حاله الحالية للذكاء الاصطناعي وليس تركيز هذه الدراسة.

### ثانياً: التعلم الآلي: و يأتي تفصيلها فيما يلي(GFDRR,2018):

1. مفهوم خوارزمية التعلم الآلي و أنواعها: خوارزمية التعلم الآلي ( MACHINE LEARNING) هي نوع من برامج الكمبيوتر التي تتعلم أداء مهام محددة بناءً على مختلف مدخلات البيانات أو القواعد التي يوفرها الإنسان. يمكنهم القيام بهذه المهام بطريقتين، وفقاً لما هو مبين في الجدول رقم (1):

الجدول رقم (1): طرق التعليم الآلي للخوارزمية

| ب- تحت الاشراف (خاضعة للرقابة)  | أ- بدون اشراف (غير خاضعة للرقابة)  |
|---|--|
|    |    |
| <p>يقوم المستخدم البشري بإدخال مجموعة بيانات تدريب "معنونة" تخبر الكمبيوتر عن الإجابة الصحيحة وغير الصحيحة. فكر في الأمر مثل بطاقات الفلاش. إذا أظهرت لشخص ما صورة قطة و أحد الكلاب، وشرح أيهما، يمكنهم استخدام هذه المعلومات لفرز صور القطط والكلاب الأخرى في المجموعات المعنية.</p> | <p>تستخدم أجهزة الكمبيوتر الأساليب الإحصائية الموجودة مسبقًا لمحاولة تجميع البيانات ذات الخصائص المتشابهة معًا. على سبيل المثال، يمكن استخدام التركيبة السكانية للمستهلك وعادات الشراء كمجموعة بيانات لبرنامج إعلاني يحاول تجميع السكان في الولايات المتحدة في أسواق أصغر وأكثر تحديدًا.</p> |

**SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.**

**ج-** التعلم العميق: يشار أيضًا إلى الشبكات العصبية الاصطناعية بالتعلم العميق. تعمل الشبكات العصبية، كما تسمى باختصار، مع عدة طبقات مخفية متداخلة بين المدخلات والمخرجات وترتبط مع بعضها البعض من خلال اتصالات تشبه الخلايا العصبية في المخ. تحتوي كل هذه الخلايا العصبية على صيغ رياضية تعمل على تحسين دقة التصنيف، وعلى الأخص باستخدام طريقة تسمى الانتشار الخلفي. عودة إلى الوراء اختصار نشر للخلف الأخطاء (النشر الخلفي قصير للانتشار العكسي للأخطاء). إنها طريقة تستخدم لحساب التدرجات بين القيم المثلى (الأوزان) في "الخلايا العصبية". يأتي مصطلح "التعلم العميق" من حقيقة أن هذه الطبقات المخفية يمكن أن تتداخل على طبقات أخرى مخفية إلى بعض العمق، ولكن لا علاقة لها بـ "العمق" الفعلي للمحتوى. بعبارة أخرى، يمكن أن تكون أساليب التعلم العميق مثل أساليب التعلم الآلي الأخرى. يمكن تطبيق التعلم العميق على مهام التعلم الآلي الخاضعة للإشراف وغير الخاضعة للرقابة.

2. مثال عن التعلم الآلي في العالم الحقيقي: نظرًا لأن الكوارث غالبًا ما تؤثر على المناطق الفقيرة والضعيفة بشكل كبير، من الضروري استخدام التكنولوجيا التي لدينا لحماية تلك المناطق. على سبيل المثال: غواتيمالا: منطقة شديدة التأثر بالزلازل، حيث أنه في عام 1976، تسبب الزلزال في تدمير مدينة لوس أميتس الغواتيمالية، مما تسبب في (أنظر الشكل رقم (2)):



الشكل رقم (2): مخلفات زلزال غواتيمالا عام 1976 م.



SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

كل من: الأعاصير، النشاط البركاني، الانهيارات الأرضية، والكوارث الأخرى التي استمرت في ضرب غواتيمالا في السنوات منذ ذلك الحين، مما أثار التساؤل هنا حول كيف يمكن لهذا لبلد أن يستعد بشكل أفضل لمخاطر الكوارث الطبيعية؟

❖ المشكلة: في مناطق النشاط الزلزالي الشديد، يمكن أن يساعد تحديد المباني عالية الخطورة في إعطاء

الأولوية لاستثمارات التعديل التحديتي، والأهم من ذلك، إنقاذ الأرواح. ومع ذلك، فإن إرسال فرق كبيرة من المساحين إلى هذا المجال يستهلك الكثير من الوقت والتكاليف.

❖ الحل: استخدم البنك الدولي صورًا مأخوذة من أقمار صناعية وطائرات بدون طيار وكاميرات مطلة على الشارع بزواوية 360° لتحديد المنازل التي كانت عرضة لخطر الانهيار أثناء الزلزال، حيث كان استخدام الصور أقل بنسبة 70% من الاعتماد فقط على الأشخاص لجمع البيانات و من الضروري منع التحيز البشري في جمع البيانات.

و لقد حددت الخوارزمية المباني عالية المخاطر بناءً على ما يوضحه الشكل رقم (3):  
الشكل رقم (3): تحديد الخوارزمية للمباني عالية المخاطر



انحدار الأرض

فتحات كبيرة في الطابق الأول

مواد على السطح

و في النهاية، أدت طريقة البنك الدولي إلى:

- 85% من المباني التي اعتبرها المهندسون الميدانيون معرضه للخطر
- المساعدة في تحديد المنازل المتواضعة التي هي عرضة للانهيار والمباني التي هي المرشحين جيده لتعديل التحديتي.

الشكل رقم (4): المباني المعرضة للخطر



ومن الواضح أن استخدام البيانات بحكمه يمكن ان يكون له نتائج هائلة عندما يتعلق الأمر بإدارة مخاطر الكوارث. ولكن-صدق أو لا تصدق-في بعض الأحيان، الأرقام تكذب. 3. منع التحيز: وبما أن جميع مجموعات البيانات تمثل تمثيلاً تقريبياً للعالم الحقيقي، فإنه لا يوجد نموذج خال من التحيز. سواء كان ذلك بسبب نموذج من البيانات لمنطقه الفقيرة، واختيار معايير غير لائقه، أو سبب آخر. ويمكن اتخاذ خطوات لمنع التحيز:

- تقييم التصورات المسبقة التي يمكن أن تتجسد في البيانات.
- ضمان أن تكون جميع البيانات ذات متناسبة مع النتائج المرجوة.
- إذا لزم الأمر، يجب القيام بجمع بيانات إضافية لبناء عينه أكبر وأقل تحيزاً.

#### المحور الثالث: دراسات حالة في إدارة مخاطر الكوارث:

تنقسم دراسات الحالة التالية إلى أربع فئات: التعرض البدني والضعف، التعرض الاجتماعي والضعف، تحديد المخاطر والتنبؤ بالأضرار، و تحديد أحداث ما بعد الكوارث وتقييم الأضرار، و سنفصل في كل حالة على حدة (GFDRR, 2018):

#### 1) التعرض البدني والضعف:

أ- الضعف الزلزالي في المناطق الحضرية في غواتيمالا: إن اكتشاف الضعف الزلزالي في المناطق الحضرية أمر بالغ الأهمية. تحديد المباني عالية الخطورة يمكن أن تنقذ الأرواح وتساعد على إعطاء الأولوية لاستثمارات التعديل التحديثي. ومع ذلك، فإن إرسال فرق كبيرة من المساحين إلى هذا المجال يستغرق وقتاً طويلاً ومكلفاً. وبدلاً من ذلك، تستفيد دراسة الحالة هذه من صور الأقمار الصناعية وطائرات بدون طيار، والصور التي يتم التقاطها في الشوارع من كاميرات الشوارع بزوايا 360 درجة لتحديد المنازل التي تشكل درجة عالية من خطر الانهيار أثناء حدوث زلزال. ساعدت نماذج الارتفاع الرقمية المستقاة من صور الأقمار الصناعية على تحديد المباني الواقعة على المنحدرات شديدة الانحدار، والتي تكون أكثر عرضة للخطر للانهيارات الطينية. و لقد ساعدت مجموعة من صور الأقمار الصناعية وصور الطائرات بدون طيار في تحديد السطح المواد، مما يشير إلى تقنيات البناء الأساسية التي هي أكثر عرضة للأنشطة الزلزالية. يعد توفر صور التجوّل ثلاثي الأبعاد فريداً، حيث يمكن استخدامه لتحديد هياكل القصة اللينة المعرضة للأنشطة الزلزالية. و تعد دراسة الحالة هذه مثلاً جيداً على كيفية استخراج عوامل الضعف المختلفة من مصادر البيانات المختلفة والقدرات الفريدة لصور التجوّل ثلاثي الأبعاد. 85% من خوارزمية التعلم العميق المدربة على صور التجوّل الافتراضي المباني التي تم وضع علامة عليها من قبل المهندسين الخبراء باعتبارها عرضة للخطر.



## الجدول رقم (1): الضعف الزلزالي في المناطق الحضرية

|   |                           |
|---|---------------------------|
| التعرف بسرعة على منازل المعرضة للزلازل "القصة الناعمة"  | هدف إدارة مخاطر الكوارث   |
| • صور بدون طيار (EBEE، RGB، 4سم)<br>• نقطة ارتفاع البيانات السحابية<br>• صور التجوّل ثلاثي الأبعاد (TRIMBLE MX، 30 ميغا بكسل)   | بيانات الإدخال المستخدمة  |
| OPENSTREETMAP طبقة الطريق   | البيانات المرجعية         |
| بكسل / كائن (بناء)  | وحدة من التحليل           |
| مستوى الحي (ثلاثة أحياء تبلغ مساحتها حوالي 10 كيلومتر مربع في غواتيمالا)  | مقياس التحليل             |
| التعليم العميق  | الخوارزمية التي استخدمت   |
| GOST/GSURR  | الذي أكمل التحليل         |
| <ul style="list-style-type: none"> <li>تقوم هذه الطريقة بفحص حي يضم 5000 منزل وهو قادر على ذلك لتحديد حوالي 500 التي تحتاج إلى مزيد من التفتيش ويمكن التعديل التحديثي / التعزيز.</li> <li>من المباني "قصة لينة" التي يرفعها المهندسين (الذين شاهدوا لهم من الخارج) هذه الطريقة اشتعلت 85٪ منهم.</li> <li>قواعد البيانات التفصيلية هذه إمكانات للإدخال في التعرض قواعد البيانات، وتحديد الأولويات التحديثية / الإسكان مشاريع التطوير.</li> <li>تم الكشف التلقائي عن فتحات الطابق الأول الكبيرة البيانات التي تم جمعها من قبل الفريق - ولكن لتوسيع نطاق، AND/OR MAPILLARY GOOGLE STREET VIEW ينبغي النظر فيها.</li> <li>كما تم استكشاف صور الأقمار الصناعية لمعرفة ما إذا كان يمكن استخدام من 50 إلى 30 سم لقياس ارتفاع المباني. تم التعاقد مع NTT وسلمت طبقة جيدة ولكن تميل إلى جمع الأسر معاً، وخاصة في الأحياء الكثيفة.</li> </ul> | النتائج والدروس المستفادة |

SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018

## الشكل رقم (5): التقييم السريع لجودة الإسكان في مدينة غواتيمالا



المصدر: سارة أنتوس، 2018. التقييم السريع لجودة الإسكان، فريق دعم العمليات الجغرافية المكانية (GOST) في البنك الدولي، واشنطن

2. التعرض الاجتماعي وسرعة التأثير

أ- رسم الخرائط للمناطق العشوائية: في عام 2012، ورقة استعرضها النظراء بقلم غرايسر وآخرون. تعيين غير رسمية المستوطنات في أربع مدن رئيسية، باستخدام خوارزمية "التعلم الآلي" لتصنيف صور الأقمار الصناعية. وفقاً للمؤلفين، في صور الاستشعار عن بُعد، تشترك المستوطنات العشوائية في خصائص مكانية فريدة تميزها عن الأنواع الأخرى من الهياكل مثل المناطق الصناعية والتجارية والسكنية الرسمية. بعد مراجعة الأدبيات الشاملة لأساليب الاستشعار عن بعد التي تم استخدامها لتحقيق أهداف مماثلة، استخدم المؤلفون العديد من ميزات الصور ذات المستوى المنخفض في نطاقات متعددة لتوصيف الأحياء المحلية، مفصلة على أساس سلسلة من الميزات المكانية والهيكلية والسياقية. غرايسر وآخرون. أوضح كيف يمكن فصل الأحياء الرسمية وغير الرسمية بشكل واضح بالنظر إلى دقة مكانية كافية للصور المستخدمة. غالباً ما تشترك المستوطنات غير الرسمية في ميزات مكانية وبنية وسياقية فريدة تفصلها عن الأنواع الأخرى من أحياء المناطق الحضرية. هذه الخصائص يمكن أن تشمل:

- عدم تجانس كبير في اتجاه المبنى (معظم المباني ليست كذلك "بدقة" موجهة على طول مساحة مخطط لها [على سبيل المثال، طريق])
- تباين كبير في مواد البناء المستخدمة وكثافة الهياكل (على عكس المستوطنات الرسمية، حيث سيكون هناك مزيد من تجانس هذه الميزات في الحي)
- حجم مبنى صغير (على عكس المباني الكبيرة مع المزيد من القصص في المستوطنات الرسمية)
- شوارع غير منتظمة وضيقة (على عكس الشوارع المخططة الأوسع والأضيق)
- الأحياء غير الرسمية التي غالباً ما تكون أقرب إلى المناطق الخطرة مثل مدافن النفايات والمطارات والسكك الحديدية والمنحدرات الأكثر حدة

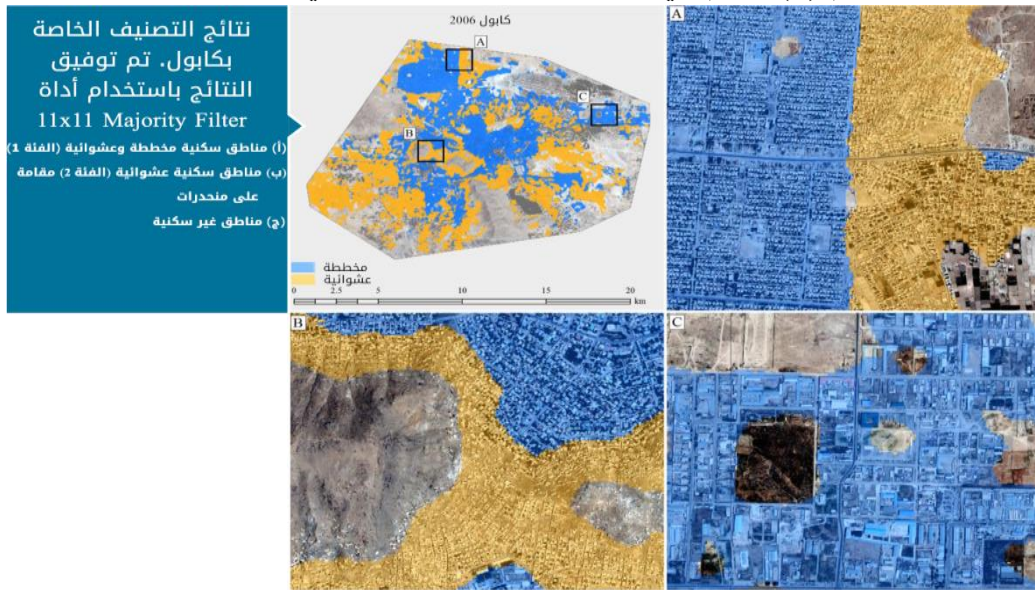
الجدول رقم (2): تحديد المستوطنات غير الرسمية

| هدف إدارة مخاطر الكوارث   | تحديد المستوطنات (المناطق العشوائية، الأحياء الفقيرة) غير الرسمية   |
|---------------------------|---|
| بيانات الإدخال المستخدمة  | <ul style="list-style-type: none"> <li>• صور الأقمار الصناعية (RGB &lt; 0.5 M) ،</li> <li>• بكسل الميزات القائمة</li> <li>• مؤشرات الغطاء النباتي</li> <li>• GLCM PANTEX (كثافة المستوطنات)</li> <li>• الملمس (النسيج) (خنزير، لاكوناريتي، توزيع الميزة الخطية، خط دعم المنطقة، فرزت، YEXTONS)</li> </ul> |
| البيانات المرجعية         | الوسم اليدوي للصور (وضع العلامات اليدوية للصور)   |
| وحدة التحليل              | بيكسل   |
| مقياس (نطاق) التحليل      | مدينة (74 كم <sup>2</sup> من قندهار، أفغانستان ؛ 203 كم <sup>2</sup> من لاباتز، بوليفيا ؛ 220 كيلومتر مربع من كابول، أفغانستان ؛ 348 كم <sup>2</sup> من كراكاس، فنزويلا)  |
| الخوارزمية التي استخدمت   | أشجار القرار  |
| الذي أكمل التحليل         | GRAESSER J B و CHERIYADAT A M و VATSAVAIR و BRIGHT E A و CHANDOLA V لمختبر أوك ريدج الوطني  |
| النتائج والدروس المستفادة | <ul style="list-style-type: none"> <li>• تم العثور على ميزات نسيج البنائي في صور القمر الصناعي SUBMETER مناسبة للتمييز بين المناطق الرسمية وغير الرسمية في المدن.</li> </ul>  |

- كان لخوارزمية التعلم الآلي دقة 85-92٪ للمدن الأربع.
  - يقترح المؤلفون قد تؤدي الطرق التي تأخذ عدة وحدات بكسل مجاورة في الاعتبار إلى تحسين النتائج.
  - تتصل الدراسة بالضعف الاجتماعي للمظهر الجسدي وترتيب المباني والطرق؛
- هذا سيعتمد على السياق المحلي، وينبغي للمرء أن يتوخى الحذر عند تطبيق النماذج على مناطق أخرى.

SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

الشكل رقم (6): رسم آلي لخريطة للمناطق العشوائية في كابول بأفغانستان



SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

### 3. تحديد المخاطر والتنبؤ بالأضرار


أ- التنبؤ بأضرار الفيضانات: تستخدم العديد من نماذج تقييم الأضرار الناجمة عن الفيضانات عمق المياه لحساب منحنيات الضرر بناءً على موقع معين و ظروف الفيضان. إن تطبيق نفس المنحنيات على مواقف مختلفة غالبًا ما ينتج عنه نتائج غير موثوقة. يبحث هذا المشروع في كيفية استخدام إدراج متغيرات إضافية لتحسين قابلية نقل نماذج التنبؤ بالأضرار الناجمة عن الفيضانات. تم بناء شبكات بايز والغابات العشوائية الانحدار لربط الضرر النسبي للمبنى أو تلف المحتوى النسبي الذي أبلغت عنه الأسر التي شملها الاستقصاء بمختلف ميزات المدخلات. توضح النتائج أن النماذج المدربة باستخدام بيانات غير متجانسة (أي أحداث الفيضانات ذات الخصائص المختلفة) تتمتع بأداء أعلى. يؤكد المؤلفون على أهمية الحصول على مجموعة تدريب غير متجانسة لنماذج أضرار الفيضانات، بما في ذلك مجموعة متنوعة من أحداث الفيضانات، والمواقع الجغرافية، وخصائص الأصول.

الجدول (3): تقييم الأضرار الناجمة عن الفيضانات

|                           |  |
|---------------------------|--|
| هدف إدارة مخاطر الكوارث   | تقييم الأضرار الناجمة عن الفيضانات   |
| بيانات الإدخال المستخدمة  | عمق الماء. • نوع البناية. • بناء مساحة البصرة. • مساحة الأرض للمعيشة<br>عمر البناء. • قبو. • حجم الأسرة • سرعة تدفق • مدة الفيضان • فترة العائد الربحي<br>• تجربة الفيضانات • تدابير وقائية  |
| البيانات المرجعية         | الأضرار النسبية للمباني والأضرار النسبية للمحتوى من المسوحات الميدانية   |
| وحدة التحليل              | جدولي (بيانات المسح)   |
| مقياس (نطاق) التحليل      | إقليمي (حدث فيضان في هولندا في عام 1993 وست أحداث فيضان في ألمانيا بين عامي 2002 و 2013)   |
| الخوارزمية التي استخدمت   | شبكات بايز والغابات العشوائية (الانحدار)   |
| الذي أكمل التحليل         | GFZ، DELTARES المركز الألماني للبحوث لعلوم الأرض   |
| النتائج والدروس المستفادة | <ul style="list-style-type: none"> <li>• يؤدي تحديث خوارزمية التعلم الآلي ببيانات من بلد مختلف إلى تحسين أداء النموذج في أحداث الفيضان من هذا البلد.</li> <li>• جمع بيانات التدريب من مختلف أحداث الفيضانات و المناطق قد تكون أكثر فعالية من كمية كبيرة من المعلومات من حدث واحد.</li> </ul> |

SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

الشكل رقم (7): نموذج تقييم الأضرار الناجمة عن الفيضانات المستندة إلى شبكة بايز الألمانية للقطاع الخاص



SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

ب- التنبؤ بالحرائق الهائلة: اخترع اثنين من طلاب المدارس الثانوية جهاز للتنبؤ باحتمال حدوث حرائق الغابات. يتم وضع الجهاز في مجموعة التفرعات ويمكنه التقاط صور في الوقت الفعلي يتم تحميلها على **SENSORINSIGHT** لتمكين التصور في الوقت الفعلي. تُستخدم خوارزميات التعلم العميق لتحليل الصور والتنبؤ بكمية الوقود الميت الموجود في منطقة المستشعر. يتم الجمع بين هذه المعلومات مع بيانات الطقس المحلية للتنبؤ باحتمال نشوب حريق، وتستخدم هذه الدراسة إلى حجم عينة صغير نسبياً ومن المحتمل أن يكون ذلك تتطلب التحقق من صحة واسعة مع بيانات مرجعية أكثر جوهرية. على الرغم من هذه العوامل، فهي دراسة حالة فريدة جداً لأنها تعرض حلاً على مستوى القاعدة وكيفية الجمع بين خوارزميات التعلم الآلي للحصول على تنبؤات بالمخاطر في الوقت الفعلي.



ويجري تطوير مستشعر SMART WILDFIRE الذي ابتكروه واختبرت مع كال فاير في ثلاث مقاطعات في ولاية كاليفورنيا.

الجدول رقم (4): التنبؤ بالحرائق الهائلة في الوقت الحقيقي

|                           |  |
|---------------------------|--|
| هدف إدارة مخاطر الكوارث   | التنبؤ بالحرائق الهائلة في الوقت الحقيقي   |
| بيانات الإدخال المستخدمة  | ❖ بيانات الطقس<br>الرطوبة - درجة الحرارة - الغاز - أول أكسيد الكربون/ثاني أكسيد - الرياح<br>❖ الصور  |
| البيانات المرجعية         | ما يقرب من 100 صورة عشوائية عينات من العشب والشجيرات من صور جوجل   |
| وحدة التحليل              | نقطة (مواقع أجهزة الاستشعار وضعت في الغابات في ولاية كاليفورنيا)   |
| مقياس (نطاق) التحليل      | إقليمي (غابات مختارة في كاليفورنيا)  |
| الخوارزمية التي استخدمت   | التعليم العميق   |
| الذي أكمل التحليل         | كال النار ومونتا فيستا الثانوية  |
| النتائج والدروس المستفادة | ❖ يصنف الصور من الأعشاب والشجيرات في 14 فئات تشير مستويات مختلفة من مخاطر حرائق الغابات بدقة 89٪.<br>❖ من المحتمل أن يتطلب النموذج مزيداً من التحقق الشامل<br>❖ في الوقت الحقيقي، نهج القاعدة الشعبية لاستخدام خوارزمية التعلم الآلي لإدارة مخاطر الكوارث. |

**SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.**

الشكل رقم (8): جهاز للتنبؤ باحتمال حدوث حرائق الغابات



**SOURCE:**

**[HTTPS://WWW.BLOG.GOOGLE/TECHNOLOGY/AI/FIGHTING-FIRE-MACHINE-LEARNING-TWO-STUDENTS-USE-TENSORFLOW-FORECAST-WILDFIRES/](https://www.blog.google/technology/ai/fighting-fire-machine-learning-two-students-use-tensorflow-forecast-wildfires/)**

4. ما بعد الكوارث رسم الخرائط و تقييم الاضرار

أ- رسم خرائط (مسح) مدي الفيضانات: طورت **ORBITAL INSIGHT** مشروعاً في عام 2017 استخدموا فيه رادار الفتحة الاصطناعية (**SAR**) كمدخل لخوارزمية تصنيف الصور التي سمحت بتصنيف المناطق المعرضة للخطر للفيضانات في هيوستن، تكساس، الولايات المتحدة الأمريكية. ساعدت صور (**SAR**) (القادرة على "النظر" عبر السحاب) في تحديد مدى الفيضان. سمحت نماذج الارتفاع الرقمية (**DEMS**) بتحديد تجمعات المياه الطبيعية، واستخدمت صور ذات علامات جغرافية متعددة المصادر لتأكيد حدود الفيضان.

الجدول رقم (5): تحديد مدى الفيضانات

|                           |   |
|---------------------------|---|
| هدف إدارة مخاطر الكوارث   | رسم خرائط مدى الفيضانات   |
| بيانات الإدخال المستخدمة  | <ul style="list-style-type: none"> <li>• صور الأقمار الصناعية الضوئية</li> <li>• صور SAR (من خلال السحاب)</li> <li>• نماذج الارتفاع الرقمية (DEMS)</li> </ul>   |
| البيانات المرجعية         | الحشد، الصور ذات علامات جغرافية   |
| وحدة التحليل              | بيكسل   |
| مقياس (نطاق) التحليل      | حدث فيضان إعصار هارفي   |
| الخوارزمية التي استخدمت   | التعليم العميق  |
| الذي أكمل التحليل         | الرؤية المدارية   |
| النتائج والدروس المستفادة | <ul style="list-style-type: none"> <li>• ساعد الجمع بين أنواع مختلفة من البيانات المكانية واسعة النطاق تقدير مدى الفيضان.</li> <li>• يمكن أن تساعد الصور ذات العلامات الجغرافية المزحمة بالحشود على التحقق من الفيضانات تحليل الدقة.</li> </ul> |

SOURCE: GLOBAL FACILITY FOR DISASTER REDUCTION AND RECOVERY , 2018.

الشكل رقم (9): خرائط الفيضانات الفعلية SOURCE: ORBITAL TREET



MAP)OURC: ORBITAL INSIGHT,

SOURCE: ORBITAL INSIGH AND GOOGLE STREET, 2017.

### الخاتمة:

ارتبط مفهوم الكوارث الطبيعية لدى الناس بمظاهرها المختلفة من: زلازل و فيضانات و حرائق و أعاصير، لكنها ان اختلفت في الأشكال أو في فترة حدوثها التي تتراوح من بين ثوان كالألزال إلى سنوات كحالات الجفاف أو في شدة أثارها التي تتفاوت حسب المكان و درجة مئانة البناء و نوعية و كثافة السكان، فإنها حتما سنتفق في النتائج من خسائر بشرية و مادية. كل ذلك يفتضي تدخل مؤسسات متخصصة و مسؤولة و وفق إجراءات و عمليات البحث و الانقاذ و هذا ما يندرج وفق مصطلح إدارة مخاطر الكوارث الطبيعية الذي يبنى على اعتبارين هما: درء أخطار الكوارث إما بإزالة مسبباتها أو بإعداد التدابير اللازمة للحد من أثارها، و تصميم التنسيق التنظيمي الفعال الذي يمكن من التحكم لمواجهة الكارثة و تقليص أضرارها و العمل على إعادة التوازن في البيئة بعد إزالة الخطر.



تعتمد إدارة مخاطر الكوارث المدفوعة بالأدلة على العديد من أنواع البيانات ومصادر المعلومات وأنواع النماذج المختلفة لتكون فعالة المهام مثل نمذجة الطقس، أو تمزق خط صدع الزلازل، أو تطوير تدابير تعرض حضرية ديناميكية تنطوي على العلوم المعقدة وكميات كبيرة من البيانات من مجموعة من مصادر، ويمكن للخبراء بذل جهد كبير لتطوير النماذج التي تمكن فهم الآثار المحتملة لخطر على البيئة الحضرية والمجتمع.

تعد خوارزمية التعلم الآلي من أنواع برامج الكمبيوتر التي تتعلم أداء مهام محددة بناءً على مختلف مدخلات البيانات أو القواعد التي يوفرها مصممها، و التعلم الآلي هو مجموعة فرعية من الذكاء الاصطناعي، ولكن غالباً ما يتم استخدام المصطلحين بالتبادل.

تراوحت دراسات الحالة في هذه الورقة البحثية من تحديد المباني المعرضة للأضرار الناجمة عن الأعاصير و الفيضانات إلى رسم خرائط للمستوطنات العشوائية التي تضم أكثر سكان المدن ضعفاً. لفهم مخاطر الكوارث، ينطبق التعلم الآلي في الغالب على الطرق المستخدمة في تصنيف أو تصنيف الأقماع الصناعية المستشعرة عن بعد والجوي وطائرة بدون طيار وحتى على التصوير على مستوى الشارع، والاستفادة من مجموعة كبيرة من العمل على التعرف على الصور وتصنيفها. لكن التطبيقات تشمل أيضاً أنواعاً أخرى من البيانات: من شبكات بيانات الاستشعار الزلزالية وبناء سجلات التفتيش إلى منشورات التواصل الاجتماعي. ويُعد التحديد الدقيق لمواضع التعرض للخطر أحد الأسس اللازمة لتحقيق إدارة أكثر فاعلية لمخاطر الكوارث. وقد شهدت منهجيات أخرى قدراً من النجاح في جمع معلومات دقيقة عن مواطن الضعف والتعرض للخطر، على سبيل المثال، من خلال إضافة مزيد من الموظفين على الأرض من أجل تقنيات المسح أو مضاعفة حملات استلهام الحلول من الجماهير سعياً إلى رسم خريطة التجمعات العمرانية. وباستخدام خوارزميات التعلم الآلي يمكن تقليص تكاليف المشروع بدرجة كبيرة سواء تم تطبيقها على صور الأقمار الصناعية أو الطائرات المسيّرة بلا طيار أو على مستوى الشوارع، أو على بيانات مستخلصة من مختلف أجهزة الاستشعار والمصادر مثل المستشعرات الزلزالية أو المقالات المنشورة على وسائل التواصل الاجتماعي.

كل التقدم الذي تم إحرازه في تطبيقات التعليم الآلي يمكن ويتم استخدامه لحل المشكلات الأكبر التي تواجه البشر من الاستفادة القصوى من أرضنا إلى الاستعداد للأزمات والتعافي منها، بحيث إذا تضافرت أجهزة الكمبيوتر والإنسان معاً، فإن ذلك سيحقق تقدم هائل في مجال إدارة مخاطر الكوارث، ومع استمرار نمو التكنولوجيا ومجموعات البيانات، ستتم نتاج أكثر.

### قائمة المراجع:

- أحمد ماجد. (2018). الذكاء الاصطناعي في الامارات، وزارة الاقتصاد في الإمارات، ص 11.  
 جودة حسنين، (1998). جغرافية الكوارث الطبيعية، دار المعرفة الجامعية، الاسكندرية، ص 9.  
 الزبير، موسى امين. (2016). " إدارة مخاطر الكوارث الطبيعية"، مجلة كلية الآداب في جامعة أفريقيا العالمية، العدد 6، ص 26.  
 غنيمات، محمد محمود. (2009). الكوارث الطبيعية – أحكامها و التدابير الشرعية المتعلقة بها، أطروحة دكتوراه، الجامعة الأردنية، الأردن، ص 17.  
 الطيب، حسن أبشر، (1992). إدارة الكوارث، مدليات المحدودة، الطبعة الثانية، ص 34.  
 سارة أنتوس، (2018). التقييم السريع لجودة الإسكان، فريق دعم العمليات الجغرافية المكانية (GOST) في البنك الدولي، واشنطن.

Orbital Insign And Google Street,(2017).

<https://www.blog.google/technology/ai/fighting-fire-machine-learning-two-students-usetensorflow-forecast-wildfires/>

<https://www.albankaldawli.org/ar/topic/disasterriskmanagement/overview>  
w 28/03/2019

<http://www.isdm.gov.sa/forum/archive/index.php?t-2.html> 28/03/2019

Gfdr Global Facility For Disaster Reduction And Recovery. (2018). Machine Learning For Disaster Risk Management, World Bank, P 7.