



بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



جامعةالسودان للعلوم والتكنولوجيا

كلية علوم الحاسوب وتقنية المعلومات

بحث تكميلي لنيل درجة الماجستير

العنوان:

تحليل تغريدات تويتر باستخدام خوارزميات العنقودة لمعرفة
أسباب إنتشار المخدرات

*Analysis of Twitter's Tweets Using clustering
algorithms to recognize the causes of drug proliferation*

إعداد:

ماجدة عبد السلام محمد سعيد العوض

إشراف:

د. طلعت محي الدين وهبي

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

((رَبُّ أَوْزَعْنِي أَنْ أَشْكُرَ نِعْمَتَكَ الَّتِي أَنْعَمْتَ
عَلَيَّ وَعَلَى وَالِدِيَّ وَأَنْ أَعْمَلَ صَالِحًا تَرْضَاهُ
وَأَدْخِلْنِي بِرَحْمَتِكَ فِي عِبَادِكَ الصَّالِحِينَ))

صدق الله العظيم

سورة النمل : 19

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

الشّكّر ونُلْقَمِبِر

شكراً لكل من قدّم لي المساعدة عند حاجتي ولكل من وقف بجانبي وأخص بالشكر أمي وأبي علي دعمهما لي في كل مراحل حياتي .

كماأشكر الدكتور هشام علي حسن تعامله وسعة صدره وتوجيهاته وعلي كل جهد بذله من أجلي .

شكراً إلي صديقي أفراح طه التي كانت بجانبي طوال فترة البحث دون ملل وكانت خير عون لي .

الملخص:

تعتبر وسائل التواصل الاجتماعي من اهم مصادر المعلومات حيث تسمح بمشاركة المعلومات بين مجموعات مختلفة من الناس حول العالم وتمكن المستخدم من الوصول الى هذه البيانات و البحث عن اراء الناس حول موضوع او منتج معين دون جهد يذكر مقارنه مع الطرق التقليديه مع ضمان موثوقيه أعلى للنتائج .

في هذا البحث تم استرجاع البيانات من تویتر حول الاستخدام السئ للمخدرات وتم تخزينها في قاعدة بيانات وتحليلها باستخدام كل من خوارزمية k-means و خوارزمية ward's لمعرفة ما هي أسباب الاستخدام السئ للمخدرات .
بعد تحليل 4000 تغريدة جمعت من تویتر عن إستخدام المخدرات وبحسب آراء مستخدمين تویتر أن 70% من أسباب إنتشار المخدرات البيئة المحيطة والعلاقات تليها أسباب نفسية ثم قلة الوعي .

Abstract

The massive developments of social media sites in the recent years have become an important source of information. Also, it allowed a great opportunity to communicate and share information between people around the world. And you can take advantage of the large quantity of data that are published daily to find out people's views about a particular product, service or personality.

The problem is that the traditional ways to find out public opinion is not effective because it includes a limited number or category of persons in addition to that there is no guarantee their credibility in answer therefore been used clustering algorithms in artificial intelligence.

This project is aimed to retrieving tweets from the social networking site (Twitter) and stored in the database to extract data to know what causes the spread of drugs abuse.

After analysis of 4000 tweets collected from Twitter about the use of drugs and according to the views of Twitter users that 70% of the causes of the spread of drugs surrounding environment and relationships followed by psychological reasons and then lack of awareness.

شرح الاختصارات التي وردت في البحث:

الاختصار	المصطلح	شرح المصطلح
API	Application Program Interface	فكرة (API) هي أن تجلب البيانات والخدمات بتنسيقات تسمح لنا بإستخدامها مرة أخرى من أي مكان ، وأشهر هذه التنسيقات هي XML و JSON .
OAuth	Open Authorization	بروتوكول مفتوح يمكن من عمل تحقق مؤمن بطريقة بسيطة وقياسية
JSON	JavaScript Object Notation	عبارة عن صيغة متسلسلة لنقل البيانات
PHP	Hypertext Preprocessor	لغة PHP هي واحدة من أشهر لغات البرمجة التي يتم إستخدامها في إنشاء موقع الويب و هي من اللغات التي يقوم خادم الويب بتفسير و تنفيذ الكود الخاص بها ثم يرسل النتيجة ليتم عرضها في متصفح المستخدم
AT	Access Token	رمز يتم استخدامه من قبل تطبيق توينر للوصول الى الموارد المحمية نيابة عن المستخدم

الفهرس

رقم الصفحة	المحتوى
أ	الابه
ب	شكر وتقدير
ج	الملخص
د	Abstract
هـ	شرح الاختصارات التي وردت في البحث
و	الفهرس
الفصل الأول	
المقدمة	
1	مقدمة
2	مشكلة البحث
2	اهداف البحث
2	حدود البحث
2	منهجية البحث
3	هيكل البحث
الفصل الثاني	
الخلفية النظرية	
4	2.1 مقدمة
4	2.2 تعدين الآراء (Opinion mining)
4	2.3 الشبكات الاجتماعية (Social network)
5	2.4 واجهة برمجة التطبيقات لتوير (Twitter API)

6	2.5 العنقة
6	2.6 طرق تجميع البيانات
10	2.7 خوارزميات العنقة(Clustering algorithm)
12	2.8 الدراسات السابقة
الفصل الثالث منهجية البحث	
22	3.1 مقدمة
23	3.2 معالجة البيانات
25	3.3 بناء مصفوفة للمستند (document-term matrix)
26	3.4 خوارزمية K-Means
27	3.5 خوارزمية ward's
27	3.6 الأدوات التي تم استخدامها في هذا البحث
الفصل الرابع التطبيق	
29	4.1 مقدمة
29	4.2 جمع البيانات
33	4.3 تحليل البيانات
36	4.4 تطبيق خوارزمية Hierarchical clustering
الفصل الخامس النتائج والتوصيات	
41	5.1 مقدمة
41	5.2 النتائج

43	5.3 التوصيات
44	الخاتمه
45	المراجع

الفصل الأول

المقدمة

الفصل الأول

المقدمة

التطور الكبير الذي حدث في وسائل التواصل الاجتماعي يعتبر ثروة في عالم البيانات ، فهناك تغريدات تضاف يوميا من مختلف المستخدمين من أماكن مختلفة حول العالم . يقوم المستخدمون بالتعبير عن كل ما يجول في خواطيرهم عن طريق الكتابة والتصريح تجاه القضايا التي يتناولونها في موقع الشبكات الاجتماعية. ومن هنا جاء تحليل الآراء كأحد الإجراءات التي يستخدمها الباحثون في مجال الاتصال الرقمي لقراءة مواقف وإتجاهات الرأي العام على تلك المنصه أي أنه إستراتيجية إتصالية للوصول إلى ما يتناوله المستخدمون على شبكات التواصل.

ومن أشهر شبكات التواصل الاجتماعي التويتر لذلك يعتبر تويتر مصدر غني بالمعلومات لـ اتخاذ القرارات وتحليل الآراء(Hridoy, Syed Akib Anwar, 2015) في هذا البحث تم اختيار تويتر كمصدر للبيانات لأنه يحتوي على عدد كبير من المستخدمين ولتحديد عدد الأحرف المستخدمة في التغريدة بـ 140 حرف فقط .

جمعت البيانات من تويتر وبعد تخزينها في قاعدة بيانات بإستخدام MySQL، حللت بإستخدام خوارزميتي k-means و ward's لمعرفة أسباب إنتشار المدررات .

1.1 مشكلة البحث:

الطرق التقليدية للبحث عن البيانات تتطلب جهداً كبيراً و تستغرق وقتاً أطول لجمع المعلومات مقارنة مع استخدام وسائل التواصل الاجتماعي كمصدر للمعلومات ، كما أن الإستخدام السئ للمخدرات يشكل خطراً على مستخدمها حيث تضر بصحة كل من عقله وجسده ؛ فمستخدمها يصبح هو نفسه خطر على مجتمعه.

1.2 اهداف البحث:

إستخدام بيانات (تغريدات) من موقع التواصل الاجتماعي (تويتر) لمعرفة أسباب الإستخدام الخاطئ للمخدرات مما يساعد في محاربتها وتقليل استخدامها.

1.3 حدود البحث:

في هذا البحث جمعت البيانات (التغريدات) حول استخدام المخدرات من الفتره بين 2018-5-12 إلى 2018-10-15 وتحليلها بإستخدام خوارزميتي k-means وward's.

1.4 منهجة البحث:

جمعت الغرييات من موقع التواصل الاجتماعي تويتر وتخزينها في قاعدة بيانات MySQL ومن ثم معالجتها بحذف الكلمات الأقل تكراراً والأحرف الزائدة وإرجاع الكلمات إلى جذورها لتسهيل عملية التحليل وبعد ذلك ، تم تحليلها بايجاد اكثر الكلمات تكرارا

ومن بعدها تم استخدام خوارزميتي k-means و ward's لمعرفة أسباب إنتشار المخدرات.

1.5 هيكل البحث:

يحتوي هذا البحث على 6 فصول ، حيث يتناول الفصل الأول مقدمة عن مشكلة وأهداف ومنهجية المشروع الذي ستنظرق له في البحث ونبذة بسيطة عما سيتم تناوله لاحقا في البحث. ويحتوي الفصل الثاني على المقدمه ، تجميع البيانات و الدراسات السابقة. يتناول الفصل الثالث منهجية البحث والأدوات التي تم إستخدامها ، كما يوضح كيفية الحصول على البيانات من التويتر وتخزينها في قاعدة البيانات . أما الفصل الرابع فيتناول خوارزميات التجميع والتصنيف في الذكاء الإصطناعي. و الفصل الخامس والأخير يحتوي على النتائج والتوصيات

الفصل الثاني

الخلفية النظرية

الفصل الثاني

الخلفية النظرية

2.1 مقدمة:

هذا الجزء من البحث يحتوي على خلفيه نظرية عن البحث ، كما يحتوي على دراسات سابقة لها علاقه بهذا البحث .

2.2 تعدين الآراء (Opinion mining)

يعرف أيضاً بإسم تحليل المشاعر (Sentiment analysis) و هدفه تحليل البيانات او النصوص بعد معالجتها للحصول علي معلومات بعرض معرفة ما يحمله النص من آراء سواء إيجابية أو سلبية أو محايده تجاه موضوع النص (Hridoy, Syed Akib Anwar, 2015).

2.3 الشبكات الإجتماعية (Social network):

الشبكة الإجتماعية هي موقع على شبكة الإنترن트 يجمع الناس معاً للحديث وتبادل الأفكار والمصالح أو تكوين صداقات جديدة (Alessa, 2018) وفيما يلي قائمة صغيرة من بعض أكبر الشبكات الإجتماعية المستخدمة اليوم :

• موقع Facebook : موقع الشبكات الإجتماعية الأكثر شعبية على شبكة الإنترنرت .

الفيسبوك هو مقصد للمستخدمين لإعداد صفحات الويب الخاصة بهم، والتواصل مع الأصدقاء، وتبادل الصور، والحديث عن ما يفعلونه ، الخ..

(<http://www.facebook.com>)

• **MySpace** : الموقع الذي كان الأكثر رواجاً قبل أن يدخل في منافسة شديدة مع

الفيس بوك مؤخراً ، وهو تطبيق يقدم شبكة تفاعلية بين الأصدقاء المسجلين في

التطبيق، ويمكن المستخدمين من نشر الصور، وكتابة المدونات، ونشر الموسيقى

. (<http://www.myspace.com>) وإرسال الرسائل

• **تويتر (Twitter)**: أحد الشبكات الأسرع نمواً حيث يقوم بتقديم خدمة التدوين

المصغر برسالة واحدة لا تتجاوز المائة والأربعون حرف، المعروفة بإسم

التغريدات، كما يمكنك متابعة الأشخاص الذين تعرفهم أو الذين كنت مهتماً بهم،

. (<http://www.Twitter.com>) وتبادل الرسائل النصية

2.4 واجهة برمجة التطبيقات لـ توير (Twitter API)

هي طريقة للوصول إلى واجهات برمجية للتطبيقات لـ تستطيع قراءة وكتابة البيانات

من حسابك في توير، والتعرف على صاحب الحساب ومعلومات عن المتابعين . توير

لديه ثلاثة واجهات برمجية للتطبيقات هي :

Search API •

REST API •

Streaming API •

Search API 2.4.1

يُسمح للمستخدمين البحث في محتوى توير وإسترجاع التغريدات وفقاً لشروط

معينة مثل إسترجاع التغريدات بلغة معينة أو من بلد معين أو تحديد عدد معين .

(Representational State Transfer) REST API 2.4.2

يتكون ال REST من مبادئ و توجيهات قابلة للتطوير والمستخدمة لإنشاء خدمات الويب ، وهو مبني بطريقة توافق مبدأ خدمات الويب (Web Services) . فهو يوفر وسيلة لنقل المعلومات بين ال (client) و (server) عن طريق بروتوكولات ال (HTTP).

يمكن المبرمجين من الوصول إلى بيانات موقع التواصل الاجتماعي توينتر (Twitter) لقراءتها مع إمكانية كتابة البيانات. أيضاً يُوفر قراءة الملف الشخصي لمنشئ التغريده المعينه و متابعين البيانات وأكثر من ذلك.

Streaming API 2.4.3

يمكن المستخدمين من البحث عن تغريدات حديثة فقط واسترجاعها .

2.5 العنقدة:

هي عملية تقسيم البيانات الى مجموعات ، حيث تحتوي كل مجموعة على مجموعة من العناصر متشابهه فيما بينها وتخالف عن العناصر في المجموعات الأخرى ؛ وذلك لتسهيل عملية التعامل مع البيانات وتحليلها (S.-H. Liao, 2012)

2.6 طرق تجميع البيانات:

توجد عدة طرق لتجميع البيانات وهي :

- طريقة التقسيم (Partitioning Method)
- الطريقة الهرمية (Hierarchical Method)
- الأسلوب القائم على الكثافة (Density-based Method)

- الأسلوب القائم على الشبكة (Grid-Based Method)
- الأسلوب القائم على نموذج (Model-Based Method)
- الأسلوب القائم على القيد (Constraint-based Method)

(Partitioning Method) 2.6.1

يتم تقسيم البيانات إلى عدد من المجموعات بحيث تحتوي كل مجموعة كائن واحد على الأقل وكل كائن يجب أن ينتمي إلى مجموعة واحدة بالضبط (S.-H. Liao, 2012)

(Hierarchical Method) 2.6.2


هذا الأسلوب يقوم بإنشاء التحليل الهرمي لمجموعة معينة من البيانات. وتوجد طريقتان لتقسيم البيانات بالطريقة الهرمية:

i. الطريقة التجميعية (Agglomerative Approach)

ويعرف هذا النهج أيضاً باسم نهج من أسفل إلى أعلى. يتم البدأ مع نقطة من المجموعات الفردية، وفي كل خطوة يتم دمج أقرب زوج من المجموعات (Han and Micheline Kamber, 2010).

ii. طريقة التقسيم (Divisive Approach)

ويعرف هذا النهج أيضاً باسم نهج من أعلى إلى أسفل . يتم البدء مع كافة الكائنات في نفس المجموعة . يتم تقسيم المجموعة إلى أن تصل إلى مجموعات أصغر (Han and Micheline Kamber, 2010)




الشكل (2.2) رسم توضيحي يمثل الطريقة الهرمية

2.6.3 الأسلوب القائم على الكثافة(Density-baseMethod)

ويستند هذا الأسلوب على فكرة الكثافة. حيث يستمر النمو في مجموعة معينة، طالما أن الكثافة لم تتجاوز حد معين، أي لكل نقطة من نقاط البيانات داخل مجموعة معينة، في دائرة نصف قطرها من المجموعة المعينة يجب أن تحتوي على ما لا يقل عن الحد الأدنى من

النقط(Han and Micheline Kamber,2010)



الشكل(2.2) رسم توضيحي يمثل يمثل الاسلوب القائم على الكثافة لتجمیع البيانات

(Grid-Based Method) 2.6.4 الأسلوب القائم على الشبكة

يتم تحديد مجموعة من شبكة الخلايا وتعيين البيانات (الكائنات) إلى خلية الشبكة المناسبة وحساب الكثافة من كل خلية. القضاء على الخلايا، ذات الكثافة الأقل في المجموعة معينة. تشكيل المجموعات من جماعات متاخرة (المجاورة) من خلايا كثيفة (Han and Micheline Kamber,2010)

(Model-Based Method) 2.6.5 الأسلوب القائم على نموذج

في هذه الطريقة يتم إفتراض نموذجاً لكل مجموعة للعثور على أفضل تناسب للبيانات لنموذج معين. هذه الطريقة تضع المجموعات عن طريق تجميع دالة الكثافة. وهو يعكس التوزيع المكاني لل نقاط للبيانات.

يوفر هذا الأسلوب أيضاً وسيلة للتحديد التلقائي لعدد من المجموعات استناداً إلى الإحصاءات القياسية، بأخذ الضوابط في الاعتبار. وبالتالي فإنه ينتج أساليب تجميع قوية (Han and Micheline Kamber,2010).


(Constraint-based Method) 2.6.6 الأسلوب القائم على القيد

في هذه الطريقة يتم تجميع البيانات عن طريق قيود تحدد من قبل المستخدم (Han and Micheline Kamber,2010)

(Clustering algorithm) 2.7 خوارزميات العنقدة

العنقدة أو التجميع هي عملية تجميع للعناصر المشابهة على شكل عناقيد Clusters حيث يتم تجميع جميع العناصر المشابهة ضمن عنقود واحد له خصائص معينة يختلف من خلاها عن

باقي العناقيد الأخرى وقد يكون هناك عناصر شاذة لا يمكن أن تنتمي إلى أي تجمع (S.-H. Liao, 2012). يوضح الشكل التالي عملية العنقدة أو التجميع:



الشكل (3.2) رسم توضيحي يمثل العنقدة أو التجميع

هناك عدد من الخوارزميات المستخدمة في عملية تجميع البيانات أو تقسيم البيانات، ومن هذه الخوارزميات التي سوف يتم الحديث عنها بشكل مفصل:

- خوارزمية (K-Medoids Clustering)
- خوارزمية (K-means Clustering)
- خوارزمية CLARA

2.7.1 خوارزمية (K-Medoids Clustering)

تستخدم هذه الخوارزمية لعنقدة أو تجميع بعض البيانات اعتماداً على خصائصها إلى K عنقود بإيجاد الوسيط لجميع العناصر، حيث تم عملية العنقدة من خلال جمع العناصر المشابهة حول مركز العنقود(الوسيط) (Han and Micheline, 2010).

:K-Means 2.7.2 خوارزمية الـ

تقوم هذه الخوارزمية بتجمیع البيانات حول مراكز يتم حسابها عن طريق ايجاد الوسط الحسابي لكل العناصر ،حيث أن العنصر الوسط هو المركز الذي تجتمع حوله بقية العناصر المشابه له (Han and Micheline Kamber,2010)

CLARA 2.7.3 خوارزمية

في هذه الخوارزمية يتمأخذ عينة تعبّر عن البيانات و من ثم تطبيق خوارزميّة (K-means, K-medoids) لإيجاد المراكز وبعدها يتم تتصیف البيانات إلى عناقيدتها المناسبة. تستخدم هذه الخوارزمية في حالة تصنیف حجم كبير جداً من البيانات وتعتمد فعالیتها على حجم العينة التي يتم اخذها من البيانات (Han and Micheline Kamber,2010)

:ward's 2.7.4 خوارزمية

خوارزمية ward's إحدى طرق التجمیع الهرمي ، حيث تبدأ بمجموعة من العناقيد كل واحد منها يحتوي على عنصر واحد فقط ،ثم تقوم بدمج العناقيد المجاورة المشابهة و تستمر بالدمج حتى تصل إلى عدد العناقيد المحدد مسبقاً أو أن تصبح جميع العناقيد المشابهة في نفس المجموعة . (Han and Micheline Kamber,2010)

2.8 الدراسات السابقة :

تعدين النصوص هي عملية القيام بتحليل مجموعة كبيرة من النصوص يصعب معالجتها بالطرق التقليدية ،ولتسهيل عملية التحليل يتم إستخدام خوارزميات مختلفة لاستخراج معلومات مفيدة(K. Sumathy,2013)

هناك مجموعة من الدراسات التي إستخدمت تحليل النصوص في مجالات مختلفة منها :


2.8.1 استخدام تويتر لتقدير المطاعم في السعودية:

Provider Reputation Service A Lexicon-based Approach to Build

:from Arabic Tweets in Twitter

هدف هذه الدراسة هو قياس السمعة من خلال تغريدات من تويتر وتم اخذ مجموعة من المطاعم كدراسة حالة (case study) لقياس سمعتهم عن طريق تحليل التغريدات المكتوبة باللهجة السعودية .

تم إنشاء قاموس بسيط لغرض الدراسة يحتوي على 1424 كلمة من اللهجة السعودية ،وبعدها تم جمع 550 تغريدة لمجموعة من المطاعم ،وتم حساب السمعة على مستوى التغريدة وعلى مستوى الكلمة ولإختبار النتائج تمت مقارنتها مع ترتيب المطاعم حسب السمعة من موقع المتخصص في تقدير المطاعمQaym . (Haifa Al-Hussaini ,2017)




الشكل(4.2) رسم توضيحي يمثل تقدير سمعة المطاعم مقارنة مع موقع Qaym

2.8.2 دراسة تقوم بتحليل المشاعر المستخدمة في التغريدات :

في هذه الدراسة تم إسترجاع تغريدات باللغة الإنجليزية ، ثم يقوم بتحليل هذه التغريدات لمعرفة نسبة التغريدات الإيجابية والسلبية ، وذلك بإستخدام خوارزمية naïve base

(د.محمد مصطفى حجور،2016)



الشكل(5.2) رسم توضيحي يمثل النتائج لتحليل التغريدات

2.8.3 التنبؤ بالجرائم عن طريق تغريدات تويتر:

إكتشف أستاذ مساعد في جامعة فرجينيا ماثيو جربر وجود علاقة بين تغريدات والجريمة. من خلال النظر في إحداثيات الموقع الجغرافي المرتبطة بالتغريدات ، يمكن للشرطة التنبؤ بالمكان الذي يحدث فيه حدوث الجريمة على الأرجح (Matthew Gerber,2013)

جمع جربر 1.5 مليون تغريدة في منطقة شيكاغو بين يناير ومارس 2013. كما قام بسحب سجلات الجريمة خلال الفترة نفسها. قام بتقسيم تغريدات على أساس الموقع الجغرافي ونظر في بيانات الجريمة لكل منطقة لمعرفة ما إذا كانت الكثافة السكانية مرتبطة بالجريمة. في النتيجة ، يمكن أن تتتبأ الطريقة بدقة "19 من 25 نوعاً من الجرائم".

وضرب لذلك مثلاً بالقول “الناس يغدون حول كيفية تمضية أيامهم، فمثلاً إن عرفاً أن فلاناً ينوي أن يمضي ليته في شرب الكحول ثم أعلن أشخاص آخرون أنهم سينضمون إليه، معنى ذلك أننا سنكون أمام احتمال وقوع مخالفات قانونية في ذاك المكان.”

وحل غربر وزملاؤه التغريدات التي كتبها أشخاص في أحياط مدينة شيكاغو، مستتدلين إلى قاعدة بيانات رسمية حول المخالفات والجرائم في المدينة، وتمكنوا بفضل ذلك من توقع بعض المخالفات التي وقعت فعلاً بعد ذلك. وجاء في الدراسة “أن هذه المقاربة تتيح تحديد المناطق حيث احتمالات وقوع جرائم فيها تكون مرتفعة، إذ أن الجرائم والمخالفات القانونية تقع غالباً في أماكن سبق تسجيل جرائم فيها، وبذلك يمكن إعداد خارطة للمناطق سيئة السمعة تكون أدلة مفيدة لتوقع الجرائم” (Matthew Gerber, 2013)

2.8.4 تحليل التغريدات التي تحتوي على معلومات طبية :

(Are Health-Related Tweets Evidence Based? Review and Analysis of Health-Related Tweets on Twitter)

تهدف هذه الدراسة إلى النظر في التغريدات التي تحتوي على معلومات طبية على تويتر للتحقق من صحتها (تستند إلى الأدلة) ولإثارة الوعي في المجتمع حول أهمية التغريدات المرتبطة بالصحة والقائمة على الأدلة. تم جمع 625 من تغريدات باللغة العربية ذات الصلة بالصحة من 8 حسابات لأطباء ، و 10 حسابات لاتنتمي للمؤسسات الصحية ، و 4 حسابات غذائية ، و 3 حسابات حكومية. وبعد مراجعة البيانات كانت النتائج أن هناك 320 (51.2%) من التغريدات خاطئة و 305 (48.8%) من التغريدات صحيحة. وأيضاً أكثر من نصف التغريدات المرتبطة بالصحة (248/169 ، 68.1 %) من المعاهد الصحية غير الرسمية

وحسابات التغذية (101/59 ، 58.4 %) كانت خاطئة. كانت التغريدات عبر الأطباء في الغالب "صحيحة" مقارنة بالمجموعات الأخرى (Khalid A Alnemer, 2015).

2.8.5 تحليل التغريدات السلبية على تويتر مؤشر للإصابة بأمراض القلب

Psychological Language on Twitter Predicts County-Level Heart Disease Mortality

هذه الدراسة أعدها فريق من الباحثين في "جامعة بنسلفانيا" ، وحلل فيها عالم النفس ، يوهانس أيكست ، وزملاؤه ، بيانات تحتوي على 826 مليون تغريدة في «تويتر» ، كتبها 90% أشخاص ينتمون إلى 1400 مقاطعة أميركية ، بين عامي 2009 و 2010 تضم نحو 90% من تعداد الولايات المتحدة وتم ربطها بمعلومات حول الوفاة بسبب أمراض القلب . و من أجل تحليل هذه المعلومات وربطها بالإصابة بأمراض القلب ، قام الفريق بتحليل لغة التغريدات المساعدة في التنبؤ بالوفيات الناجمة عن الإصابة بأمراض القلب إستناداً على نموذج تعلم الانحدار / الآلة (regression/machine learning model)

حيث شهدت المقاطعات — التي تضمنت تغريدات سكانها كلمات تتصل بالخصوصية والعدائية والكراهية والإرهاق، مثل "أحمق" و"غير" و"ضجر" — معدلات أعلى بشكل ملحوظ من الوفيات الناجمة عن تصلب الشرايين، ومن ذلك النوبات القلبية والسكريات . وعلى النقيض من ذلك ، كانت أمراض القلب أقل شيوعاً في المناطق التي عكست تغريدات سكانها مشاعر أكثر إيجابية ومشاركة (Johannes C. Eichstaedt, 2015).


2.8.6 تحليل للرأي العام الإلكتروني عقب إستهداف الأماكن المقدسة

Analyze and monitor the comments users of social networking site (Twitter) about the bombing of the Medina:

تم إعداد هذه الدراسة لتحليل ورصد تعليقات مستخدمي موقع التواصل الاجتماعي (تويتر) حول حادثة تفجير المدينة المنورة لتحليل تعليق الرأي العام العربي على هذا الحادث وكيف تم وصف القائم به.

وبيّنت النتائج أن أكثر من ثلث المستخدمين (36.4%) وصفوا ما حدث أنه تفجير، بينما ربط ربع المستخدمين 25% الحادث بداعش و 20.5% وصفوا الحادث بالإرهاب . وأظهرت الدراسة أن 84.1% من المغردين تحدثوا عن نتائج التفجير فيما غرد 4.5% فقط عن الحادث نفسه . كما بيّنت أن غالبية المغردين (51.1%) إستخدموا إطار الإتهام في وصف الحادث و 18.2% إطار التعاطف .

من جانب آخر، أشارت النتائج أن 29.3% من المغردين يشيرون إلى أن سبب التفجير بعض الحكومات العربية بينما أشار 22% أن هناك مؤامرة ما وراء التفجير . غطّت الدراسة نشاط المستخدمين خلال عشر أيام من التفجير وإستخلصت الآف التغريدات المتعلقة بالحادثة بطريقة تحليل البيانات الكبيرة (big data) وذلك لأخذ عينات بأسلوب أكاديمي لتحليل إتجاهات الرأي العام بمجمله حول آراء المغردين العرب التي تم التعبير عنها الكترونياً . ومن جانب آخر عبر 4.5% عن حزنهم بما حدث و 4.5% كانوا تحت تأثير الصدمة خصوصاً أن إستهداف الإرهاب للمدينة المنورة والمسجد النبوي وفي الشهر الكريم كان صادماً للمغردين وعملية دموية يصعب تفسيرها (د.فاطمة السالم، 2018).



الشكل(6.2) رسم توضيحي يمثل نتائج تحليل الرأي العام الإلكتروني عقب إستهداف

الأماكن المقدسة

ملخص:

البحث	المنهجية	المجال	النتيجة
(Haifa Al-Hussaini and Hmood)201	» 1424 كلمة من اللهجة السعودية		وتم حساب السمعة على مستوى الكلمة وللختبار
	» تم جمع 550 تغريدة لمجموعة من المطاعم	تقييم المطاعم	مستوى الكلمة وللختبار
	» التصنيف classification FP growth(النتائج تمت مقارنتها مع ترتيب المطاعم حسب السمعة من موقع Qaym
			تقييم المطاعم

<p>65% تغريدات إيجابية</p>	<p>تحليل المشاعر المستخدمة في التغريدات</p> <p>► تم إسترجاع تغريدات باللغة الإنجليزية</p> <p>► لمعرفة نسبة التغريدات الإيجابية والسلبية</p> <p>► خوارزمية naïve base</p>	<p>د. محمد مصطفى حجور، 2016</p>
<p>التنبؤ بالجرائم العسكرية</p>	<p>► حل تغريدات "شيكاغو"، مستندين إلى قاعدة بيانات رسمية حول المخالفات والجرائم في المدينة</p>	<p>ماثيو جبر 2013</p>

<p>التحقق من صحة المعلومات الطبية</p> <p>هناك (51.2%) 320 من التغريدات خاطئة و (48.8%) 305 من التغريدات صحيحة.</p>	الطب	<p>تم جمع 625 من تغريدات باللغة العربية ذات الصلة بالصحة من 8 حسابات لأطباء ، و 10 حسابات لاتتنمي للمؤسسات الصحية ، و 4 حسابات غذائية ، و 3 حسابات حكومية .</p> <p>تم التقييم من قبل أطباء مختصين وتصنيفها إلى صواب وخطأ.</p>	خالد النمر ، 2015
<p>التغريدات السلبية على تويتر مؤشر للإصابة بأمراض القلب حيث شهدت المقاطعات التي تضمنت تغريدات سكانها كلمات تتصل بالخصوصية</p>	الطب	<p>التبؤ بالوفيات الناجمة عن الإصابة بأمراض القلب إستناداً على نموذج تعلم الانحدار / الآلة (regression/machine learning model)</p>	Johannes C. Eichstaedt, 2015

<p>والعدائية والكراهية</p> <p>والإرهاق، مثل "أحمق"</p> <p>- و"غيور" و"ضَجر" -</p> <p>معدلات أعلى بشكل ملحوظ من الوفيات الناجمة عن تصلب الشرايين</p>			
---	--	--	--

استخدمت الدراسات السابقة بيانات نصية تم الحصول عليها من موقع التواصل الاجتماعي توينر حول مواضيع مختلفة ، وبعد تحليلها باستخدام طرق وخوارزميات تختلف من دراسة إلى أخرى حسب المعلومات المطلوب الحصول عليها .

يتفق هذا البحث مع الدراسات المذكورة أعلاه في استخدام بيانات تم جلبها من توينر وتحليلها لاستخراج معلومات مفيدة ويختلف في المواضيع التي تتناولها تلك البيانات ،ففي هذا البحث تم جلب بيانات متعلقة بالمخدرات والإدمان . وأيضاً يختلف في طريقة التحليل والخوارزميات المتبعة حيث تم استخدام طريقة العنقدة لنقسم البيانات إلى مجموعات مختلفة .

الفصل الثالث

منهجية البحث

الفصل الثالث


منهجية البحث

3.1 مقدمة:

يحتوي هذا الفصل على المنهجية التي إستخدمها الباحث في كل مراحل البحث من بداية جمع المعلومات وصولاً إلى استخراج النتائج.

في هذا البحث تم جمع البيانات المتعلقة بالمخدرات والإدمان المكتوبة باللغة الإنجليزية من موقع التواصل الاجتماعي توينتر بإستخدام كود php ، وتم تخزينها في قاعدة بيانات ومن ثم ، تمت معالجتها عن طريق تقسيم الجملة إلى كلمات منفصلة وحذف المساحات الفارغة الكبيرة وعلامات الترقيم ، وأيضاً تحويل الأحرف الكبيرة إلى أحرف صغيرة لتنقیل مساحة تخزينها في الذاكرة وتسهيل وتسریع عملية تحلیلها ثم إزالة الزوائد التي تستخدم للربط بين الكلمات ولا تؤثر على الرأي عند حذفها مثل الحروف المساعدة وإرجاع كل كلمة إلى اصلها .Term-Matrix (الجزء) وتخزينها في مصفوفة

الخطوة التالية هي تقليل حجم المصفوفة عن طريق حذف الكلمات الأقل تأثيراً (تكراراً) وتخزين الأكثر تكراراً في مصفوفة جديدة . وتم تحلیلها وتقسیمها إلى مجموعات باستخدام خوارزميتي Ward's K-means لمعرفة أسباب إنتشار المخدرات.



الشكل(1.3) رسم توضيحي يمثل منهجية البحث

3.2 معالجة البيانات:

عند تحليل أي نوع من البيانات لابد ان تسبق عملية التحليل معالجة للبيانات وذلك لتهيئة البيانات وحذف ما قد يسبب ضوضاء منها، يمكن أن تحدث هذه الضوضاء بسبب ممارسات جمع البيانات من عدة مصادر، فقد البيانات عن طريق الخطأ ، وبيانات الملوثات مثل التعديلات غير الصحيحة ، والحذف أو الإضافات، أو في كثير من الحالات لمجرد أن البيانات تحتوي على حالات لا علاقه لها بهدف مهمة استخراج البيانات (Han and Micheline Kamber,2010)

وفي هذا البحث تم اجراء المعالجة بالخطوات الموضحة في الجدول التالي:

مثال	الشرح	الخطوة
Bad friends take you to addiction.	اذا كان لدينا تغريدة من توينتر عن المخدرات	جمع البيانات
Bad Friends Take You to addiction.	نقسيم الجملة الى كلمات منفصلة اعتماداً على المسافات بين الكلمات لتبسيط عملية المعالجة	التقسيم (tokenization)
bad Friend Take Addiction	إزالة الزوائد وإستبدال الأحرف الكبيرة بالصغيرة والحروف.	التصغير (normalization) وتحذف حروف الوقف stop word
bad Friend Take Addict	إرجاع الكلمة الى جذرها	النابعة (stemming)

الجدول (3.1) معالجة البيانات

3.3 بناء مصفوفة للمستند (document-term matrix)

هي مصفوفة رياضية تصف تكرار الكلمات في مجموعة من الوثائق(البيانات). حيث تمثل الصفوف المستندات وتمثل الأعمدة المصطلحات ، ويتم تمثيلها بـ 1 في حال ظهور الكلمة في المستند و 0 في حالة عدم الظهور ، ومن هنا يمكن تحديد أهمية المصطلح حيث أن المصطلحات الأكثر تكراراً هي الأكثر أهمية. على سبيل المثال في حال وجود مستندين س،ص

	1	2	3	4	5
abus	1	0	0	0	0
drug	1	1	1	0	1
love	1	0	1	1	0

الجدول(3.2) مصفوفة المستند

في هذا البحث تم إنشاء مصفوفة تحتوي على 21176640 عنصر ولتسهيل عمل الخوارزمية تم حذف الكلمات القليلة التكرار وتكون خوارزمية جديدة تحتوي على 343440 عنصر .

الآن بعد أن أصبحت البيانات ممثلة على صورة مصفوفة جاهزة للتحليل باستخدام خوارزميات مختلفة ، وفي هذا البحث تم استخدام خوارزميتي Ward's و k-means .

3.4 خوارزمية K-Means :

تقوم هذه الخوارزمية بتجمیع البيانات حول مراكز يتم حسابها عن طريق ایجاد الوسط الحسابي لكل العناصر ،حيث أن العنصر الوسط هو المركز الذي تجتمع حوله بقية العناصر المشابه له [3].

طريقة عمل خوارزمية الK-means :

1. تحديد عدد التجمعات K.
2. تحديد إحداثيات مراكز التجمعات Centroid عشوائياً لأول مرة ويتم حسابه عن طريق إیجاد (متوسط النقاط التي تتبع للمركز) لباقي المراکز.
3. حساب المسافة بين كل عنصر وبين جميع المراكز، ويتم استخدام البعد الإقلیدي.

يعطى البعد الإقلیدي d_{ij} بين مثالين زرقاء بالعلاقة التالية :

$$(1) d_{ij} = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2}$$

حيث إن :

n: عدد العناصر المراد تصنیفها الى مجموعات.

$x_{ik} - x_{jk}$: فرق إحداثيات العناصر بعد تمثيلها على المستوى الديكارتي.

4. تجمیع العناصر مع أقرب مركز لها.

وتتكرر الخطوات 4 ونقل المراكز حتى نتوصل الى امثل نموذج حيث يتم تصنیف كل عنصر الى مجموعته المناسبة.

:ward's خوارزمية 3.5

خوارزمية ward's إحدى طرق التجميع الهرمي ، حيث تبدأ بمجموعة من العناقيد كل واحد منها يحتوي على عنصر واحد فقط ، ثم تقوم بدمج العناقيد المجاورة المتشابهة وتستمر بالدمج حتى تصل إلى عدد العناقيد المحدد مسبقاً أو أن تصبح جميع العناقيد المتشابهة في نفس المجموعة .

تحدد هذه الخوارزمية العناصر المتشابهة عن طريق حساب الإختلاف بين النقاط ، حيث أن العناصر المتشابهة هي الأقل اختلاف .

3.6 الأدوات التي تم إستخدامها في هذا البحث:

wamp serve • 2.5 الإصدار

MySQL • 5.6.17 الإصدار

RStudio •

3.6.1 WampServer

هو بيئة لتطوير تطبيقات الويب على نظام التشغيل ويندوز (Windows) ، تم تصميمه بواسطة (Romain Bourdon) . هذه البيئة متاحة مجاناً بموجب ترخيص البرنامج العالمي (GPMI) في نسختين متميزتين : 32 و 64 بت . تسمح البيئة للمطورين بإنشاء تطبيقات الويب باستخدام (Apache2) ، لغة البرمجة (PHP) و قاعدة البيانات (MySQL) . كما تحتوي البيئة على جزء يُسمى (PhpMyAdmin) الذي يسمح للمطور بسهولة إدارة قواعد البيانات .

3.6.2 MySQL


تعرف MySQL بأنها قاعدة بيانات، وهي طريقة من طرق الاحفاظ بالبيانات، وقاعدة البيانات تتكون من جداول والجداول تحتوي على صفات وأعمدة وخلايا. تتكون أي قاعدة بيانات غالباً من عدة جداول، ويحمل كل جدول إسماً مختلفاً يميزه مثلًا "customers" أو "orders" أو "products" ، وكل جدول يتكون من صفات تحتوي البيانات.

R لغة 3.6.3

عبارة عن مجموعة متكاملة من البرمجيات التي تسمح بمعالجة البيانات، القيام بعمليات حسابية و إظهار البيانات الرسمية و يمكن تحميل لغة R من الموقع الرسمي لها

على الشبكة والموجود على العنوان <http://www.r-project.org>

تتكامل R مع RStudio وتعتبر بيئة تطوير متكاملة (IDE) لتوفير مزيد من الوظائف فهي تجمع بين محرر شفرة المصدر ، وبناء أدوات التشغيل الآلي والمصحح.



الشكل(2.3) رسم توضيحي يمثل RStudio

الفصل الرابع

التطبيق

الفصل الرابع

التطبيق

4.1 مقدمة:

في هذا الفصل سيتم توضيح كيفية الحصول على البيانات من موقع التواصل الاجتماعي توينتر وتخزينها في قاعدة بيانات ومن ثم معالجة البيانات وتطبيق خوارزمي Ward's و K-Means لتقسيم البيانات لمجموعات حيث تتنمي العناصر المتشابهة لنفس المجموعة.

4.2 جمع البيانات:

4.2.1 إنشاء حساب في توينتر:

الخطوة الأولى هي انشاء حساب في توينتر عن طريق الموقع الرسمي لتوينتر

<https://twitter.com>

4.2.2 المصادقة و التفويض في توينتر

المصادقة : هي عملية التحقق من هوية المستخدم.

التفويض أو الإذن : هو عملية التتحقق من أن المستخدم لديه الحق في تنفيذ بعض الجراءات، مثل قراءة وثيقة أو الوصول إلى حساب البريد الإلكتروني.

4.2.3 إنشاء تطبيق تويتر:

يمكنك إنشاء التطبيق من خلال هذا الرابط <https://apps.twitter.com>: ويطلب

التطبيق إدخال إسم التطبيق ووصف عنه ورابط موقعك . يجب الموافقة على الشروط المكتوبة

ثم الضغط على إنشاء تطبيق (Create your twitter application)

The screenshot shows the 'Create an application' page. It includes fields for Name (1), Description (2), Website (3), and a Callback URL field containing 'تجاهل هذه الخانة' (4). Below these is a 'Developer Agreement' section with a checkbox for 'Yes, I agree' (5) and a large red arrow pointing to the 'Create your Twitter application' button (6).

الشكل (1.4) رسم توضيحي يمثل إنشاء تطبيق تويتر

4.2.4 الصلاحيات بعد إنشاء تطبيق تويتر

بعد إنشاء التطبيق يعطى المستخدم الصلاحيات التي تمكّنه من الوصول إلى جميع


المعلومات وهي :

• مفتاح المستهلك Consumer key .

• الرقم السري للمستهلك Consumer secret .

• رمز الوصول Access token .

• الرقم السري للوصول Access secret .



الشكل (2.4) رسم توضيحي يمثل الصلاحيات التي تعطى للمستخدم بعد إنشاء تطبيق تويتر

4.2.5 الحصول على البيانات

تم إنشاء ملف من نوع **PHP** وتم إستخدام الدالة **twitteroauth()** للإستفادة من الصلاحيات التي تم الحصول عليها من الخطوة السابقة.

تم إستخدام **search API** لاسترجاع مجموعة من التغريدات المكتوبة باللغة الإنجليزية والتي تحتوي على كلمة مخدرات أو إدمان ، وتم جمع ما يقارب 5 الف تغريدة وتخزينها في قاعدة بيانات لنتم معالجتها وتحليلها.

get(<https://api.twitter.com/1.1/search/tweets.json?lang=en&count=100&q=drug&-filter:retweet>



الشكل(3.4) رسم توضيحي يمثل الحصول على البيانات من تويتر وتخزينها

phpMyAdmin

Server: mysql_wampserver » Database: project » Table: tweets

	Browse	Structure	SQL	Search	Insert	Export	Import
	Edit Copy Delete	id	text				
1	Edit Copy Delete	1	6â€¢ Mayors in the Phillipines are getting assassi...				
2	Edit Copy Delete	2	RT : Dismissed IPS officer and now a abusive trol...				
3	Edit Copy Delete	3	Martin County Sheriff deputies: â€œMeth is backâ€...				
4	Edit Copy Delete	4	Potent psychedelic drug DMT makes the brain think ...				
5	Edit Copy Delete	5	RT : CBI arrests MDM Gutkha manufacturer Madhav Ra...				
6	Edit Copy Delete	6	RT : Nyaope drug dear where there was iphintombi ...				
7	Edit Copy Delete	7	How many republicans hot away with murder over the...				
8	Edit Copy Delete	8	RT : Sanjiv Bhatt detained on charges of growing o...				
9	Edit Copy Delete	9	RT : Working in a pharmacy I have literally seen p...				
10	Edit Copy Delete	10	RT : Kenyan lady who found her childhood friend o...				
11	Edit Copy Delete	11	RT : Kenyan lady who found her childhood friend o...				
12	Edit Copy Delete	12	RT : Kenyan ladyÂ who found her childhood friend ...				
13	Edit Copy Delete	13	RT : Kenyan lady who found her childhood friend on...				
14	Edit Copy Delete	14	FOOT PATROL AND DISTRIBUTION OF DRUG AWARENESS FLY...				
15	Edit Copy Delete	15	RT : If Drug Dealers had an Anime				
16	Edit Copy Delete	16	RT : Kenyan lady who found her childhood friend o...				
17	Edit Copy Delete	17	RT : Kenyan lady who found her childhood friend o...				
18	Edit Copy Delete	18	PCI DOMINADOR B. DE GUZMAN JR., COP, together with...				
19	Edit Copy Delete	19	RT : New drug approved for advanced lung cancer by...				
20	Edit Copy Delete	20	RT : Kenyan lady who found her childhood friend o...				
21	Edit Copy Delete	21	RT : Kenyan lady who found her childhood friend o...				

الشكل(4.4) رسم توضيحي يمثل نموذج للبيانات التي تم الحصول عليها من تويتر

4.3 تحليل البيانات :

يحتوي هذا الجزء من البحث على معالجة البيانات و تطبيق خوارزميتي ال-K-Means و Ward's Means لتقسيم البيانات لمجموعات حيث تتضمن العناصر المشابهة لنفس المجموعة.

4.3.1 تحميل البيانات إلى R:

تم تصدير البيانات من قاعدة البيانات إلى ملف نصي (file.txt) ومن ثم تحميله إلى R بإستخدام الدالة `readLines(file.Choose())` ، فهي تمكن المستخدم من استعراض الملفات وتحديد المستند المطلوب تحميله.

4.3.2 معالجة البيانات:

معالجة البيانات هي عملية تنظيف البيانات وإزالة الزوائد وعلامات الترقيم وارجاع الكلمات إلى جذورها بعد أن تم تقسيم الجمل إلى كلمات (Han and Micheline Kamber,2010).

في هذا البحث تم إستخدام المكتبة tm التي تحتوي على مجموعة من الدوال لمعالجة النصوص مثل الدالة `tm_map()` التي إستخدمت في هذا البحث لحذف الأحرف الخاصة (”,“@”) والمساحات الكبيرة بين الكلمات وتحويل الأحرف الكبيرة إلى الصغيرة . كما أن الأرقام حذفت بإستخدام الدالة `removeNumbers()`

1.3.3 بناء مصفوفة للكلمات:

تم بناء المصفوفة باستخدام الدالة (TermDocumentMatrix) ولحذف الكلمات الأقل تكرار removeSparseTerms، وهذا أصبحت البيانات مُعدة لـ استخدام الخوارزمية عليها.

1.3.4 إيجاد الكلمات الأكثر تكراراً في البيانات:


توفر لغة البرمجة R إمكانية تحليل البيانات وإجراء حسابات إحصائية وتحاليل إستكشافية على البيانات للحصول على نتائج معينة. قمنا بالاستفادة من هذه الخاصية لإيجاد أكثر الكلمات تداولاً في التغريدات التي تم جمعها سابقاً وذلك بإتباع الخطوات التالية :

- تحميل الحزم المطلوبة وهي (tm,ggplot) وإستدعاء مكتباتها .
- تحديد رقم يمثل أقل ظهور الكلمة وقمنا بإختيار الرقم 150 بحيث يتم جلب كل الكلمات التي تكررت على الأقل 150 مرة وعدد الكلمات هي 150 كلمة بالشكل التالي .

	word	freq
drug	drug	1480
stress	stress	1297
friend	friend	920
poor	poor	684
cultur	cultur	676
work	work	539
school	school	470
relationship	relationship	447
financ	financ	443
addict	addict	313

الشكل (5.4) رسم توضيحي يمثل تكرار الكلمات في البيانات

1.3.5 إنشاء المخطط البياني لأكثر الكلمات تكراراً :




الشكل (6.4) رسم توضيحي يمثل لأكثر الكلمات تكراراً

من المخطط السابق نجد أن أكثر الكلمات هي "drug" وقد تكررت أكثر من 1400 مرة تليها كلمة "stress" بمعدل 1297 مرة.

4.3.6 إنشاء سحابة الكلمات : (Word Cloud)

تعد سحابة الكلمات واحدة من أفضل الأدوات التي تسمح لنا تصوّر معظم الكلمات والمصطلحات الواردة في التغريدات على الرغم من الإستخدام الرئيسي لها هو لأغراض إستكشافية، فهي لديها ميزة أن تكون مفهومية من قبل معظم المستخدمين، وأن تكون جذابة بصرياً إلى العين البشرية. وقمنا بإنشاء سحابة الكلمات بإتباع الخطوات التالية :

- تحميل الحزم المطلوبة وهي (WordCloud,RColorBrewer) وإستدعاء مكتباتها .
- حساب عدد الظهور لأكثر الكلمات تكراراً وترتيبها تنازلياً.
- رسم ال WordCloud لأكثر الكلمات تكراراً بالشكل التالي:



شكل(7.4) رسم توضيحي يمثل سحابة الكلمات

4.4 تطبيق خوارزمية Hierarchical clustering

تعتمد هذه الخوارزمية على تقسيم البيانات بشكل هرمي.

4.4.1 كيفية عمل الخوارزمية

نفترض أنه لدينا مجموعة من البيانات "N" و مصفوفة مسافة $N \times N$ (المصفوفة تحتوي على المسافة بين البيانات)


نقوم باتباع الخطوات التالية :

1. نبدأ بوضع كل البيانات في مجموعة على حدة وبالتالي إذا لدينا N من البيانات تصبح

لدينا N من المجموعات.

2. كل أقرب زوج من البيانات يتم دمجها في مجموعة واحدة.

3. يتم حساب المسافة للبيانات التي تم دمجها (حساب المسافة تستخدم طريقة تسمى single linkage clustering والتي تعتمد على حساب المسافة من أقرب نقطة إلى حساب الجديد).
4. تكرار الخطوات 2 و 3 إلى أن تصبح البيانات كلها في مجموعة واحدة.



الشكل(8.4) رسم توضيحي يمثل عناقيد البيانات بإستخدام خوارزمية ward's

4.4.2 تطبيق خوارزمية (K Means)

1. تحديد عدد التجمعات K، وهي تعتبر خطوة تهيئة أولية. وفي هذه الحالة تصبح عدد

الجماعات تساوي 6 لأننا نريد تقسيم التغريدات إلى 4 فئات (قلة الوعي والجهل،

البيئة المحيطة والعلاقات ، أسباب نفسيه ، اخرى) ، $k = 4$.

2. تحديد إحداثيات مراكز الجماعات Centroid عشوائياً لكل كلمة لأكثر الكلمات

تكراراً. وذلك لكل فئة من الفئات للمرة الأولى فقط.

3. -حساب المسافة بين كل البيانات ومراكز التجميع. قبل حساب المسافة يتم ترميز

البيانات إلى أرقام على أساس هذه الأرقام يتم حساب المسافة بين مركز التجمع

والبيانات.

4. تجميع البيانات وتنظيمها في 4 مجموعات بناءً على أقل المسافات بين المركز ونقط


البيانات.

عده يتم تنفيذ الخطوات من 2 - 3 حتى الوصول إلى حالة الثبات.

```
> kmeansResult[["centers"]]
      abus      drug      love      back      two      abuseand      addict
1 0.79326923 0.5985577 0.1514423 0.021634615 0.01201923 0.007211538 0.2283654
2 0.03636364 0.6128603 0.1458980 0.038580931 0.02217295 0.030155211 0.2820399
3 0.30198020 0.6262376 0.1410891 0.014851485 0.01732673 0.027227723 0.1955446
4 0.13939394 0.6484848 1.3454545 0.006060606 0.02424242 0.036363636 0.2121212
      caus      child      common      death      depriv      hunger
1 0.1105769 0.01442308 0.007211538 0.04567308 0.002403846 0.002403846
2 0.1157428 0.01019956 0.002660754 0.06917960 0.027937916 0.001773836
3 0.1237624 0.01485149 0.000000000 1.19801980 0.034653465 0.002475248
4 0.1090909 1.17575758 1.169696970 0.17575758 1.115151515 1.163636364
      loss      physiolog      sexual      stressor      conflict      famili
1 0.36538462 0.002403846 0.009615385 0.002403846 0.33653846 0.7860577
2 0.05144124 0.000000000 0.035476718 0.000000000 0.000000000 0.1135255
3 0.08663366 0.000000000 0.027227723 0.000000000 1.35396040 1.5173267
```

الشكل (9.4) تحديد مراكز الجماعات عشوائياً لكل فئة بإستخدام ال R

Histogram of cluster



الشكل (10.4) رسم توضيحي يمثل عناقيد البيانات (cluster) بإستخدام خوارزمية k-means

الفصل الخامس

النتائج والتوصيات

الفصل الخامس

النتائج والتوصيات

5.1 مقدمة:

يتناول هذا الفصل النتائج التي تم التوصل إليها والتوصيات التي تخص المشروع.

5.2 النتائج:

تم إنشاء مصفوفة تحتوي على 343440 كلمة و تطبيق خوارزمية ward's k_means لتحليلها .

5.2.1 التحليل بإستخدام خوارزمية ward's:

في هذا البحث تم استخدام هذه الطريقة لتقسيم البيانات إلى 4 مجموعات لمعرفة الأسباب الرئيسية لانتشار المخدرات وكانت النتائج كالتالي:

Hierarchical	العنقود (cluster)
%16	قلة الوعي أو الجهل
%65	البيئة المحيطة والعلاقات
%12	أسباب نفسية
%7	أسباب أخرى

الشكل (1.5) رسم توضيحي يمثل عناقيد البيانات (cluster) بإستخدام خوارزمية ward's

5.2.2 التحليل بإستخدام خوارزمية K-Means :

تم إستخدام الدالة kmeans لتقسيم البيانات المخزنة في مصفوفة الكلمات (البيانات التي جمعت من تغريدات توينر حول المخدرات والإدمان) إلى 4 مجموعات أو عناقيد باتباع خوارزمية الـ K-Means . وكانت النتائج كالتالي:

K-means	العنقود (cluster)
%13	قلة الوعي أو الجهل
%70	البيئة المحيطة والعلاقات
%12	أسباب نفسية
%5	أسباب أخرى

الشكل (2.5) رسم توضيحي يمثل عناقيد البيانات (cluster) بإستخدام خوارزمية k-means

5.2.3 مقارنة لنتيجة الخوارزميتين أعلاه :

تم إنشاء مصفوفة تحتوي على 343440 كلمة و تطبيق الخوارزميتين أعلاه لتحليلها وتم التوصل إلى أسباب إنتشار المخدرات بحسب آراء مستخدمين توينر :

K-means	Hierarchical	العنقود (cluster)
%13	%16	قلة الوعي أو الجهل
%70	%65	البيئة المحيطة والعلاقات
%12	%12	أسباب نفسية
%5	%7	أسباب أخرى

الجدول (3.5) يوضح نتيجة تحليل التغريدات المتعلقة بإستخدام المخدرات

نجد ان الخوارزميتين اتفقنا علي أن السبب الرئيسي لانتشار المخدرات بحسب رأي مستخدمي توينر يرجع إلى البيئة وال العلاقات المحيطة تليها قلة الوعي والجهل بأضرار المخدرات ومن ثم الأسباب النفسيه لمستخدم المخدرات بنسبة 12% للخوارزميتين وأخيراً تأتي أسباب أخرى كالفراغ وعدم المسؤوليه .

5.3 التوصيات :

- i. يمكن تطبيق خوارزميات التصنيف Classification algorithms و خوارزميات تجميع اخرى و مقارنة النتائج بنتائج المتحصلة عليها.
- ii. إضافة بيانات من وسائل تواصل إجتماعية اخرى مثل الفيسبروك .

الخاتمة

تم بحمد الله ما اردنا جمعه وكتابته عن تحليل التغريدات حول أسباب إنتشار المخدرات وتصنيفها إلى الفئات المحددة سلفاً حيث قمنا باستخدام خوارميات التجميع في الذكاء الاصطناعي وتطبيقها على التغريدات المخزنة في قاعدة البيانات.

وكان نتائج التحليل أن هنالك 5 أسباب أتفق عليها كثير من أراء المغردين أهمها البيئة المحيطة لذلك أرجو من الآباء الإهتمام بالبيئة التي ينمو فيها أبنائهم وتوعيتهم بأضرار المخدرات وتخسيص وقت لمشاركة الحديث والفكار ومعرفة مشاكلهم ومساعدتهم في إيجاد الحلول.

المراجع:

- Anwar Hridoy, S., Ekram, M., Islam, M., Ahmed, F. and Rahman, R. (2015). .1
Localized twitter opinion mining using sentiment analysis. *Decision Analytics*,
2(1).
- McCormick, T., Lee, H., Cesare, N., Shojaie, A. and Spiro, E. (2015). Using .2
Twitter for Demographic and Social Science Research: Tools for Data
Collection and Processing. *Sociological Methods & Research*, 46(3), pp.390-
421.
- Han, J., Kamber, M. and Pei, J. (2011). *Data Mining*. Burlington: Elsevier .3
Science.
- Alessa, A., & Faezipour, M. (2018). A review of influenza detection and .4
prediction through social networking sites. *Theoretical biology & medical
modelling*, 15(1), 2. doi:10.1186/s12976-017-0074-5.
- Developer.twitter.com. (2019). *Standard search API*. [online] Available at: .5
[https://developer.twitter.com/en/docs/tweets/search/api-reference/get-search-
tweets.html](https://developer.twitter.com/en/docs/tweets/search/api-reference/get-search-tweets.html) [Accessed 12 Mar. 2019].
- Kooi, B. (2013). Assessing the correlation between bus stop densities and .6
residential crime typologies. *Crime Prevention and Community Safety*, 15(2),
pp.81-105.
- Khalid A Alnemer, F. (2019). *Are Health-Related Tweets Evidence Based?* .7
Review and Analysis of Health-Related Tweets on Twitter. [online] PubMed
Central (PMC). Available at:
<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4642373/> [Accessed 12 Mar.
2019].
- Eichstaedt, J., Schwartz, H., Kern, M., Park, G., Labarthe, D., Merchant, R., .8
Jha, S., Agrawal, M., Dziurzynski, L., Sap, M., Weeg, C., Larson, E., Ungar,
L. and Seligman, M. (2015). Psychological Language on Twitter Predicts
County-Level Heart Disease Mortality. *Psychological Science*, 26(2), pp.159-
169.
- Kim, D. and Kim, J. (2014). Public Opinion Sensing and Trend Analysis on .9
Social Media: A Study on Nuclear Power on Twitter. *International Journal of
Multimedia and Ubiquitous Engineering*, 9(11), pp.373-384.

Liao, S., Chu, P. and Hsiao, P. (2012). Data mining techniques and applications – A decade review from 2000 to 2011. *Expert Systems with Applications*, 39(12), pp.11303-11311..
Al-Hussaini, H. and Al-Dossari, H. (2017). A Lexicon-based Approach to .10 Build Service Provider Reputation from Arabic Tweets in Twitter.
International Journal of Advanced Computer Science and Applications, 8(4).

L.Sumathy, K. and Chidambaram, M. (2013). Text Mining: Concepts, .11 Applications, Tools and Issues An Overview. *International Journal of Computer Applications*, 80(4), pp.29-32.

— د.محمد مصطفى حجور، تحليل الأراء في تويتر. (2016). حمص. pp. مجلة جامعة البعث .41 العدد 83 المجلد

13. القبس الإلكتروني. (2019)، تحليل للرأي العام الإلكتروني عقب استهداف الأماكن المقدسة: مؤامرة ضد السعودية.. تاريخ الإطلاع 20نوفمبر2018 <http://alqabas.com/163631/>