نحن نقدم أداة لرصد وتصنيف خطاب الكراهية

تعتبر المعالجة الفعالة من التطبيقات الأكثر أهمية في مجال الذكاء الاصطناعي، حيث يتم من خلالها تحليل كميات كبيرة من البيانات النصية في وقت قصير جدًا، وهو ما يمثل تحديًا كبيرًا للطرق التقليدية التي تعتمد على الجهد البشري. ومع ذلك، فإن هذه التقنيات ليست خالية من العيوب، إذ يمكن أن تعكس التحيزات الموجودة في البيانات التي تُدرَّب عليها، مما يؤدي إلى نتائج غير دقيقة أو حتى ضارة. في هذه المقالة، سنستعرض أحد هذه التطبيقات، وهو تطوير أداة لرصد وتصنيف خطاب الكراهية، ونناقش التحديات المرتبطة بها.



بقلم: أ. سلمى الورداني

٢٠٢٤/٠٦/١٥

المقدمة

على مدار العقد الماضي، شهدنا تزايدًا مقلقًا في انتشار خطاب الكراهية عبر منصات التواصل الاجتماعي، مما أدى إلى تأثيرات سلبية على المجتمعات والأفراد. وقد دفع هذا الوضع العديد من الباحثين والمطورين إلى البحث عن حلول تقنية لمواجهة هذه الظاهرة. وتهدف هذه المقالة إلى تقديم نظرة شاملة على أداة تم تطويرها مؤخرًا لرصد وتصنيف خطاب الكراهية، بالإضافة إلى مناقشة التحديات التي واجهتنا أثناء عملية التطوير.

الأهداف الرئيسية للبحث

تهدف الدراسة إلى تحقيق مجموعة من الأهداف الرئيسية، التي يمكن تلخيصها على النحو التالي:

أولًا: بناء مجموعة بيانات ضخمة ومتنوعة لخطاب الكراهية. تم جمع ما يقارب مليون تغريدة من منصة تويتر، وتم تصنيف جزء منها يدويًا إلى فئات مختلفة، مثل الكراهية العنصرية، والكراهية الدينية، والتنمر الإلكتروني. وقد استغرقت هذه العملية وحدها أكثر من ستة أشهر، وشارك فيها فريق من المتطوعين.

ثانيًا: تطوير نموذج للتعلم الآلي قادر على التمييز بين أنواع مختلفة من خطاب الكراهية. استخدمنا في البداية نماذج تقليدية مثل آلة المتجهات الداعمة (SVM) والانحدار اللوجستي، ثم انتقلنا إلى نماذج أكثر تعقيدًا مثل الشبكات العصبية العميقة. وقد أظهرت النتائج أن النماذج العميقة تتفوق بشكل ملحوظ على النماذج التقليدية، خاصة عند التعامل مع النصوص القصيرة.

ثالثًا: تقييم أداء النموذج على مجموعة بيانات مستقلة. لضمان عدم وجود تحيز في النتائج، قمنا بتقييم النموذج على مجموعة بيانات لم يتم استخدامها في أي مرحلة من مراحل التدريب. وقد أظهرت النتائج أن النموذج يحقق دقة تصل إلى ٨٥٪، وهو ما يعتبر أداءً جيدًا في هذا المجال.

المنهجية

اعتمدت الدراسة على منهجية مختلطة، تجمع بين الأساليب الكمية والنوعية. وقد استخدم كل منهج لتحقيق أهداف محددة، على النحو التالي:

المنهج الكمي: تم استخدام هذا المنهج في مرحلة جمع البيانات وتحليلها. وقد تضمن ذلك استخدام أدوات آلية لجمع التغريدات، وتطبيق خوارزميات التعلم الآلي لتصنيفها، وحساب مقاييس الأداء المختلفة.

المنهج النوعي: تم استخدام هذا المنهج في مرحلة تحليل الأخطاء. فبعد تقييم النموذج، قمنا بمراجعة عينة من التغريدات التي تم تصنيفها بشكل خاطئ، وحاولنا فهم الأسباب الكامنة وراء هذه الأخطاء. وقد ساعدنا هذا التحليل في تحديد نقاط الضعف في النموذج، واقتراح طرق لتحسينه.

النتائج

أظهرت النتائج أن النموذج المطور قادر على تحقيق أداء جيد في تصنيف خطاب الكراهية، حيث بلغت دقته ٨٥٪، وهو ما يعتبر مقبولًا في هذا المجال. كما أظهرت النتائج أن النماذج العميقة تتفوق على النماذج التقليدية، خاصة عند التعامل مع النصوص القصيرة. وقد أرجعنا ذلك إلى قدرة النماذج العميقة على التقاط العلاقات المعقدة بين الكلمات، والتي لا يمكن للنماذج التقليدية اكتشافها.

التحديات والقيود

واجهنا خلال مراحل البحث العديد من التحديات، التي يمكن تلخيص أبرزها على النحو التالي:

التحيز في البيانات: لاحظنا أن بعض الفئات، مثل الكراهية ضد المثليين، كانت ممثلة بشكل أقل في البيانات، مما أثر سلبًا على أداء النموذج في هذه الفئات. وقد حاولنا معالجة هذه المشكلة من خلال استخدام تقنيات لزيادة حجم البيانات، ولكنها لم تكن كافية.

الغموض اللغوي: يعتبر الغموض اللغوي من أكبر التحديات التي تواجه أي نظام لمعالجة اللغة الطبيعية. فالكلمات يمكن أن تحمل معاني مختلفة في سياقات مختلفة، وهو ما يصعب على النموذج فهمه بشكل صحيح.

التطور المستمر للغة: تتطور اللغة باستمرار، حيث تظهر كلمات جديدة وتختفي أخرى. وهذا يعني أن النموذج يحتاج إلى تحديث مستمر لكي يظل فعالًا.

الخاتمة

في الختام، يمكن القول إن تطوير أداة لرصد وتصنيف خطاب الكراهية يعد خطوة مهمة في مواجهة هذه الظاهرة. ومع ذلك، فإن هذه الأداة ليست حلًا سحريًا، وهي تحتاج إلى تطوير مستمر لكي تظل فعالة. ونحن نعتقد أن التعاون بين الباحثين والمطورين والمجتمع المدني هو السبيل الأمثل لمواجهة هذا التحدي.

المراجع

[1] https://www.ohchr.org/en/freedom-of-expression
[2] https://www.ohchr.org/en/freedom-of-expression
[3] https://www.ohchr.org/en/freedom-of-expression