



نظام مصادقة التأليف للنصوص العربية باستخدام خوارزميات التعلم الآلي

رسالة مقدمة الى كلية الهندسة جامعة الفيوم
ضمن متطلبات الحصول على درجة الماجستير فى العلوم الهندسية

قسم الهندسة الكهربية
(تخصص هندسة الحاسبات و النظم)

إعداد

م/ مي شعبان احمد محمد براني

إشراف

أ.د/ رانيا أحمد عبد العظيم أبو السعود

أستاذ الإشارات الرقمية بقسم الهندسة الكهربية
كلية الهندسة جامعة الفيوم
(المشرف الرئيسي)

د/ أحمد سلامة إسماعيل أمين

مدرس بقسم نظم المعلومات
كلية الحاسبات والمعلومات جامعة الفيوم
(المشرف المشارك)

كلية الهندسة- جامعة الفيوم
الفيوم- جمهورية مصر العربية
أبريل، 2024

ملخص البحث

ظنَّ الاستخدام العالمي السريع للإنترنت، تلعب مصادقة التأليف اليوم دوراً حاسماً في تحديد الهوية الحقيقية للمؤلف أو أصل العمل المكتوب. هي الطريقة التي يحاول اللغوي من خلالها معرفة من كتب عملاً مجهولاً بناءً على اللغة المستخدمة والأسلوب اللغوي للكاتب. لقد تم بذل جهد بحثي كبير لمحاولة حل هذه المشكلة. في البداية كانت هذه الجهود مبنية على أنماط إحصائية، وفي الأونة الأخيرة ركزت على مجموعة من التقنيات بدءاً من الذكاء الاصطناعي. تم تحقيق اختراق مبكر مهم من قبل موستلر ووالاس في عام 1964 [1]، اللذين كانا رائدين في استخدام "الكلمات الوظيفية" - عادة الضمائر، وحروف العطف، وحروف الجر - باعتبارها السمات التي يركز عليها اكتشاف أنماط الاستخدام ذات الصلة بمؤلفين محددين.

كان التركيز الرئيسي هو دراسة اللغة الإنجليزية والإسبانية والألمانية. ونظراً لصعوبة الجمل العربية وطولها، فقد أولى الأكاديميون اهتماماً أقل باللغة. على مدى العقدين الماضيين، توسعت النصوص العربية على شبكة الإنترنت بشكل كبير، مما جعلها رابع أكثر اللغات استخداماً. ومن هنا، هناك طلب كبير على التصنيف الفعال للنص العربي.

يعد تصنيف النص مجالاً كبيراً في الذكاء الاصطناعي التطبيقي. باستخدام التعلم الآلي والتكنولوجيا المتقدمة الحديثة، يمكن أتمتة مهمة التصنيف مما يؤدي إلى معالجة فائقة السرعة وفعالة. في مهام تصنيف النص، تعد المعالجة المسبقة لمجموعة البيانات وعملية اختيار الميزات مهمة جداً لتحقيق أفضل نتيجة. قد يكون أداء المصنف الضعيف الذي يتم تغذيته بميزات ذات معنى أفضل من المصنف القوي الذي يتم تغذيته بميزات منخفضة الجودة.

في هذه الرسالة، تمت مناقشة مشكلة توثيق التأليف فيما يتعلق بالعديد من الاهتمامات العربية باستخدام مجموعة بيانات مكونة من عشرة مؤلفين مختلفين (الفارابي، الغزالي، الجاحظ، المسعودي، المقرئ، الطبري، التوحيدي، ابن الجوزي، ابن رشد، وابن سينا). يحتوي كل كاتب على 60 ملفاً نصياً، لذا تحتوي مجموعة البيانات على 600 ملف. يبدأ هيكل النهج الخاص بنا بالمعالجة المسبقة لمجموعة البيانات التي تتضمن إزالة كلمات الإيقاف والتطبيع والترميز والإنشاء لدراسة تأثير المعالجة المسبقة على أداء المصنفات المختلفة.

لقد اختبرنا تقنيات مختلفة لاستخلاص الميزات مثل (TF-IDF) - (BOW) بالإضافة إلى ميزات البنية والمعجم وبناء الجملة والدلالات واسلوب الكتابة لدراسة تأثيرها على اللغة العربية. العملية التي تتبع استخراج الميزات هي اختيار الميزات، والمعروف أيضاً باسم اختيار السمات. يسعى إلى استخراج مجموعة فرعية من الميزات الأكثر أهمية من مساحة الميزات المتفرقة دون الإضرار بأداء المصنف. بعد

ذلك، يتم تقييم متجهات الميزة المحددة باستخدام عدة طرق تصنيف. قمنا بالتحقق من أداء عشر خوارزميات تصنيف،

نقوم stacking بما في ذلك (MLP)-(SVC)- (RF)- (LR)- (MNB)- (KNN)- (SGD)- (DT)- (BC)- (GBC) .
أيضاً بوصف وتقييم النهج المختلط الذي يجمع بين المصنفات باستخدام مصنف لتحسين الأداء التنبئي العام بشكل فعال. أظهرت النتائج أن المصنف Stacking باستخدام LR كمصنف تعريفي مع مصنفين أساسيين قد حقق دقة قدرها 96% واستخدام Stacking باستخدام LR باعتباره المصنف التعريفي مع استخدام ثلاث مصنفات أساسية قد حقق دقة بنسبة 96.67%.
بالإضافة الي ذلك حقق Stacking باستخدام RF كمصنف تعريفي مع مصنفين أساسيين دقة قدرها 97% في حين حقق Stacking باستخدام RF كمصنف تعريفي مع ثلاث مصنفات أساسية دقة قدرها 98.33%.
تم ايضاً استخدام اختيار ميزة Chi-squared لتعزيز فعالية الميزات المحددة و تحسين أداء نموذج Stacking.