

مهارات بحثية ٢ - الاسبوع العاشر
المهمة العاشرة

تنبؤ بإمكانية الإصابة بمرض السكري مع التعلم العميق : نموذج الهجين
LSTM و ESA
د. محمد الحصني وآخرون
٢٠٢٢

إعداد الطالب/
منصور عبده الصعدي
دكتوراه تقنية المعلومات
٢٣٣٠٠١٦٥٠

٢٠٢٥



نقد الدراسات المرجعية

١. تنوع الأساليب المستخدمة في الدراسات السابقة

من خلال الدراسات السابقة التي تم الرجوع إليها في هذه الدراسة، يمكن ملاحظة أن هناك تنوعاً في الأساليب والطرق التي استخدمها الباحثون في محاولة تشخيص مرض السكري. فبعض الدراسات اعتمدت على تقنيات تعلم الآلة التقليدية مثل الانحدار اللوجستي ودعم الآلات الشعاعية (SVM)، بينما استخدم آخرون الشبكات العصبية الاصطناعية (ANN) ورغم أن هذه الأساليب أظهرت نتائج جيدة في بعض الأحيان، إلا أن الدراسات الحديثة بدأت تركز بشكل أكبر على استخدام تقنيات مثل LSTM (الشبكات العصبية طويلة وقصيرة المدى) التي تتمتع بقدرة على التعامل مع البيانات التسلسلية وغير الخطية بشكل أكثر فعالية. النقطة المهمة التي تسلط عليها الدراسة هي قدرة النموذج الهجين LSTM مع ESA على تجاوز بعض القيود التي كانت موجودة في الأساليب التقليدية. على سبيل المثال، بينما يمكن أن تكون تقنيات مثل SVM فعالة في بعض الحالات، إلا أنها قد تفشل في التنبؤ بدقة في المواقف التي تتطلب فهماً أعمق للبيانات المعقدة والزمانية، وهو ما يوفره نموذج LSTM المتقدم.

نقد الدراسات المرجعية

٢. استخدام مجموعة بيانات موثوقة

تعتمد الدراسة بشكل رئيسي على مجموعة بيانات "Pima Indians" التي تُستخدم بشكل واسع في العديد من الدراسات السابقة المتعلقة بتشخيص مرض السكري. هذه المجموعة تتضمن العديد من السمات الصحية المهمة مثل مستوى السكر في الدم، ضغط الدم، ومؤشر كتلة الجسم (BMI)، وغيرها من المتغيرات التي تلعب دوراً أساسياً في التشخيص. من خلال استخدام هذه المجموعة، تضمن الدراسة أنها تُستند إلى مجموعة بيانات موثوقة ومتاحة للدراسات السابقة. هذه النقطة تعزز مصداقية النتائج التي تم التوصل إليها، حيث يتمكن الباحثون من مقارنة نتائجهم بسهولة مع دراسات أخرى سابقة. ومع ذلك، تظل إحدى التحديات هي أن هذه المجموعة قد تكون محدودة من حيث تنوع البيانات، خصوصاً في السياقات التي قد تختلف فيها العوامل البيئية أو الجغرافية.

نقد الدراسات المرجعية

٣. الجمع بين تقنيات متعددة لتحسين الأداء

إحدى الابتكارات الرئيسية في هذه الدراسة هي الجمع بين تقنيتين متقدمتين هما ESA (تحليل الدلالات الصريحة) و LSTM فبينما تُستخدم ESA لاستخراج السمات الأكثر ارتباطاً بالبيانات، يُستخدم LSTM للتعامل مع هذه السمات وتقديم تنبؤات دقيقة. يسمح هذا الجمع بالتعامل مع نوعين من التحديات في البيانات: استخراج السمات المميزة والمهمة ومن ثم استخدام تلك السمات في نموذج يمكنه التعامل مع البيانات التسلسلية. هذا النموذج الهجين يحقق فوائد أكبر مقارنة باستخدام أي من الأساليب التقليدية بشكل منفصل. هذه التقنية قد تكون مفيدة للغاية في العديد من المجالات الأخرى، مثل التنبؤ بالأمراض أو في تحليل البيانات ذات البُعد الزمني.

جوانب القوة

إحدى الجوانب القوية في هذه الدراسة هي النتيجة التي تم تحقيقها من حيث دقة التنبؤ. حيث أن النموذج الهجين الذي جمع بين LSTM وESA أظهر دقة تصل إلى ٨٦.٤% في التنبؤ بإصابة مرض السكري، وهي نتيجة تُعدّ واعدة مقارنة ببعض النماذج التقليدية مثل SVM أو ANN. تقدم هذه الدقة مؤشرًا قويًا على أن استخدام تقنيات الذكاء الاصطناعي المتقدمة، مثل LSTM، يمكن أن يكون له دور كبير في تحسين دقة التنبؤات في مجال الصحة. بينما قد تكون هناك نماذج أخرى قد تظهر دقة مشابهة أو أقل، يظل هذا النموذج الهجين مرشحًا قويًا لتحسين تشخيص المرضى.

جوانب القوة

من الواضح أن الدراسة تعكس تقدمًا ملحوظًا في استخدام التقنيات الحديثة في تعلم الآلة. فاعتماد الباحثين على الشبكات العصبية طويلة وقصيرة المدى (LSTM) يعكس التوجه الحالي في استخدام الشبكات العصبية للتعامل مع البيانات التسلسلية. بالإضافة إلى ذلك، استخدام ESA لاستخراج السمات يشير إلى أن الباحثين قد استخدموا تقنيات مبتكرة لتحسين القدرة على التعرف على الأنماط في البيانات. هذه التقنيات المتقدمة تمنح النموذج قدرة استثنائية على التعلم من البيانات بدقة عالية، مما يمكن أن يحسن التشخيص الطبي ويقلل من احتمالية الخطأ في التنبؤ.

جوانب القوة

تعد مقارنة النموذج الهجين مع النماذج الأخرى مثل SVM و ANN أحد أوجه القوة الرئيسية في الدراسة. فبالمقارنة مع هذه النماذج التقليدية، يقدم النموذج الهجين أفضل النتائج من حيث الدقة. وهذه المقارنة تُظهر بوضوح فوائد النموذج الهجين وتُبرهن على فعاليته في التنبؤ بإصابة مرض السكري. بالإضافة إلى ذلك، تشير هذه المقارنة إلى أن دمج تقنيات مختلفة يعزز من الأداء مقارنة باستخدام أي تقنية منفردة، وهو درس قيم يمكن أن يُطبّق في العديد من المجالات الأخرى.

جوانب الضعف

على الرغم من أن مجموعة بيانات "Pima Indians" تُعد واحدة من الأكثر استخدامًا في أبحاث تعلم الآلة المتعلقة بمرض السكري، إلا أن استخدامها الحصري قد يمثل قيدًا في دراسة يمكن أن تُعمم على جمهور أوسع. فهذه القاعدة تمثل فقط مجموعة واحدة من البيانات، ما يعني أنها قد تكون محدودة في قدرتها على التنبؤ للأفراد الذين لا ينتمون إلى هذه المجموعة. وعلى الرغم من أن النتائج كانت قوية، من الأفضل اختبار النموذج على مجموعات بيانات متنوعة أكثر تمثل سكانًا من جنسيات وأعراق مختلفة لتقييم مدى قدرة النموذج على التكيف مع السياقات المتنوعة.

جوانب الضعف

لا تركز الدراسة بشكل كافٍ على تقييم شامل للنموذج، مثل استهلاك الموارد أو الوقت المستغرق في عملية التدريب. على الرغم من أن الدراسة أظهرت دقة عالية، إلا أن أداء النموذج من حيث السرعة أو استهلاك الموارد قد يكون ذا أهمية في التطبيق العملي. في بعض الحالات، قد تتطلب النماذج الأكثر دقة وقتًا أطول في التدريب أو استهلاكًا أكبر للموارد الحاسوبية، مما قد يكون غير عملي في البيئات التي تتطلب استجابة سريعة.

جوانب الضعف

رغم أن الدراسة تقدم فكرة عامة عن كيفية دمج ESA مع LSTM، إلا أن التفاصيل التقنية حول كيفية تكامل هذه التقنيات مع بعضها البعض قد تكون غير واضحة للقارئ. قد تحتاج الدراسة إلى توضيح أكبر حول كيفية تصميم النموذج الهجين بشكل تفصيلي، خاصة في ما يتعلق بتحديد السمات ودمجها في شبكة LSTM. هذا الغموض قد يجعل من الصعب فهم العمليات التقنية بشكل كامل، ما يعيق القارئ أو الباحثين الآخرين من إعادة تطبيق النموذج.

المرجع

Albargathe, S. m. (2022).
نموذج العميق: التعلم مع السكري بمرض الإصابة بإمكانية تنبؤ LSTM
و ESA الهجين. Retrieved from
https://www.researchgate.net/publication/385550894_nmwdhj_almyq_altlm_m_alskry_bmrdr_aalsabt_bamk_anyt_tnbw_LSTM_w_ESA_alhjyn



مجموعة جامعة
الجميع الذكية
للتعليم القابضة

MIDOCEAN
UNIVERSITY



Thank You

