تحسين الكشف عن الاكتئاب الشديد باستخدام الذكاء الاصطناعي وتحليل إشارات الدماغ

تأليف

مدرس الدكتور محمد لوتي

أبريل 10, 2026

اقتبس من هذا المقال

مدرس الدكتور محمد لوتي (2026). تحسين الكشف عن الاكتئاب الشديد باستخدام الذكاء الاصطناعي وتحليل إشارات الدماغ. عرب سايكلوجي. تم الاسترجاع من https://arabpsychology.com/?p=120502

ARABPSYCHOLOGY.COM

هل يمكن لقراءة موجات الدماغ أن تكشف عن الاكتئاب بدقة أكبر؟

أتعرف هذا الشعور؟ ذلك الثقل الذي لا يزول، والظلال التي تخيم على كل شيء، والفراغ الذي يلتهم الفرح. الاكتئاب ليس مجرد حزن عابر؛ إنه عاصفة تجتاح العقل، وتغير من طريقة تفكيرنا وشعورنا وتصرفنا. لكن، ماذا لو كان بإمكاننا رؤية هذه العاصفة، ليس من خلال كلمات المريض، بل من خلال إشارات كهربائية خفية في دماغه؟ هذا هو السؤال الذي يحاول الباحثون الإجابة عليه، والنتائج الأولية واعدة للغاية.

الإطار النظري

لطالما سعى علم النفس إلى فهم الآليات البيولوجية الكامنة وراء الاضطرابات النفسية. الاكتئاب، على وجه الخصوص، مرتبط بتغيرات في مستويات النواقل العصبية مثل السيروتونين والدوبامين والنورأدرينالين. لكن هذه التغيرات الكيميائية ليست سوى جزء من الصورة. تعتبر النظرية المعرفية السلوكية (CBT) من بين النظريات الرائدة في فهم الاكتئاب، حيث تركز على العلاقة بين الأفكار والمشاعر والسلوكيات. ولكن، كيف تتجلى هذه العمليات المعرفية في النشاط الكهربائي للدماغ؟

هنا يأتي دور مخطط كهربية الدماغ (EEG). يعمل EEG كـ "ميكروفون" للدماغ، يسجل النشاط الكهربائي الناتج عن ملايين الخلايا العصبية التي تتواصل مع بعضها البعض. تختلف أنماط هذه الإشارات الكهربائية باختلاف الحالة العقلية للشخص. في حالة الاكتئاب، غالبًا ما تظهر أنماط EEG تغيرات في موجات الدماغ، مثل زيادة النشاط في الفص الأمامي الأيسر (المرتبط بالمشاعر السلبية) وانخفاض النشاط في الفص الأمامي الأيمن (المرتبط بالمشاعر الإيجابية). الهدف من البحث الحالي، كما يوضح الباحث أكشاي كومار شودري، هو تحسين دقة اكتشاف هذه الأنماط المميزة للاكتئاب باستخدام تقنيات متقدمة.

التعلم الآلي وتقدير الاحتمال الأقصى

التعلم الآلي (Machine Learning) هو فرع من فروع الذكاء الاصطناعي يسمح لأجهزة الكمبيوتر بالتعلم من البيانات دون أن تتم برمجتها بشكل صريح. في هذا السياق، يتم تدريب خوارزميات التعلم الآلي على التعرف على الأنماط المميزة للاكتئاب في بيانات EEG. ولكن، ليست كل قنوات EEG بنفس الأهمية. هنا يأتي دور تقدير الاحتمال الأقصى (MLE). MLE هي تقنية إحصائية تستخدم لتحديد القنوات التي تحمل أكبر قدر من المعلومات حول حالة الاكتئاب. بمعنى آخر، تساعد MLE في تصفية "الضوضاء" في بيانات EEG والتركيز على الإشارات الأكثر أهمية.

المنهجية

قام شودري وفريقه بجمع بيانات EEG من مجموعتين: مجموعة من الأشخاص المصابين باضطراب الاكتئاب الشديد، ومجموعة ضابطة من الأشخاص الأصحاء. تم التأكد من أن المجموعتين متطابقتان قدر الإمكان من حيث العمر والجنس ومستوى التعليم لضمان مقارنة عادلة. تم تسجيل بيانات EEG باستخدام مجموعة من الأقطاب الكهربائية الموضوعة على فروة الرأس. بعد جمع البيانات، تم تطبيق MLE لتحديد القنوات الأكثر أهمية. ثم تم استخدام هذه القنوات المدخلة إلى مصنف الشبكة العصبية متعددة الطبقات (MLPNN)، وهو نوع من خوارزميات التعلم الآلي.

تم تدريب MLPNN على التعرف على الأنماط المميزة للاكتئاب في بيانات EEG. تم تقييم أداء المصنف باستخدام مقاييس

ARABPSYCHOLOGY.COM

مختلفة، مثل الدقة (Accuracy)، والحساسية (Sensitivity)، ومعدل الخطأ (Error Rate). تم مقارنة أداء MLPNN باستخدام MLE مع أداء MLPNN بدون MLE، بالإضافة إلى استخدام تقنية تحليل المكونات الرئيسية (PCA) كطريقة أخرى لاختيار القنوات.

النتائج

أظهرت النتائج أن استخدام MLE لتحسين اختيار القنوات أدى إلى تحسين كبير في دقة اكتشاف الاكتئاب. فقد ارتفعت الدقة من 77.77٪ في الأساس إلى 83.33٪ باستخدام PCA، ثم إلى 86.66٪ باستخدام MLE. انخفض معدل الخطأ بشكل مماثل، من 22.23٪ إلى 13.34٪ باستخدام MLE. كانت دقة التنبؤ (Prediction Accuracy) مثيرة للإعجاب بشكل خاص، حيث بلغت 100٪ باستخدام MLE، مقارنة بـ 98.02٪ باستخدام PCA. كما ارتفعت معدلات الإيجابية الحقيقية (True Positive Rates) من 70٪ إلى 74.77٪ باستخدام MLE.

تشير هذه النتائج إلى أن أنماط EEG تختلف بشكل واضح بين الأشخاص المصابين بالاكتئاب والأشخاص الأصحاء، وأن MLE يمكن أن تساعد في الكشف عن هذه الاختلافات بدقة أكبر. بمعنى آخر، يمكن لـ MLE أن تساعد في "تصفية" الإشارات غير الضرورية والتركيز على الإشارات التي تحمل أكبر قدر من المعلومات حول حالة الاكتئاب.

الآثار السريرية والعملية

هذه النتائج لها آثار كبيرة على كل من الأطباء والمرضى. بالنسبة للأطباء، يمكن أن توفر هذه التقنية أداة تشخيصية موضوعية وموثوقة للمساعدة في تحديد الأشخاص المصابين بالاكتئاب. يمكن أن يكون هذا مفيدًا بشكل خاص في الحالات التي يكون فيها التشخيص صعبًا، أو عندما يكون المريض غير قادر على التعبير عن مشاعره بوضوح. بالنسبة للمرضى، يمكن أن يؤدي التشخيص المبكر والدقيق إلى علاج أسرع وأكثر فعالية. كما يمكن أن يساعد في تقليل وصمة العار المرتبطة بالاضطرابات النفسية.

بالإضافة إلى ذلك، يمكن استخدام هذه التقنية لتتبع استجابة المريض للعلاج. من خلال مراقبة التغيرات في أنماط EEG، يمكن للأطباء تحديد ما إذا كان العلاج فعالاً أم لا، وتعديل خطة العلاج وفقًا لذلك. هذا يمكن أن يؤدي إلى نتائج علاجية أفضل وتحسين نوعية حياة المرضى.

السياق الثقافي العربي

عند النظر إلى هذه النتائج في السياق العربي، من المهم مراعاة بعض العوامل الثقافية. في العديد من المجتمعات العربية، لا يزال هناك وصمة عار كبيرة مرتبطة بالاضطرابات النفسية، مما قد يمنع الأشخاص من طلب المساعدة. قد يكون من الصعب أيضًا على المرضى التعبير عن مشاعرهم بشكل علني، خاصةً إذا كانوا يشعرون بالخجل أو الخوف من الحكم. لذلك، يمكن أن تكون الأداة التشخيصية الموضوعية مثل EEG مفيدة بشكل خاص في هذه المجتمعات، حيث يمكن أن تساعد في تجاوز الحواجز الثقافية وتوفير تشخيص دقيق وموثوق.

ومع ذلك، من المهم أيضًا أن ندرك أن أنماط EEG قد تختلف بين الثقافات المختلفة. قد تكون هناك اختلافات في النشاط الكهربائي للدماغ المرتبطة بالعوامل الثقافية مثل اللغة والدين والأسلوب المعيشي. لذلك، من الضروري إجراء المزيد من البحوث لتحديد ما إذا كانت النتائج التي تم الحصول عليها في الدراسات الغربية قابلة للتعميم على السكان العرب. كما يجب أن نأخذ في الاعتبار أن التعبير عن الاكتئاب قد يختلف بين الثقافات المختلفة، وأن الأعراض الجسدية قد تكون أكثر

ARABPSYCHOLOGY.COM

شيوعًا من الأعراض النفسية في بعض المجتمعات العربية.

التوجهات المستقبلية والقيود

على الرغم من أن هذه النتائج واعدة، إلا أن هناك حاجة إلى مزيد من البحوث لتأكيد هذه النتائج وتوسيع نطاقها. تشمل التوجهات المستقبلية تطوير خوارزميات تعلم آلي أكثر تطوراً، واستكشاف طرق جديدة لاختيار القنوات، وجمع بيانات EEG من عينات أكبر وأكثر تنوعًا. كما من المهم دراسة تأثير العوامل الثقافية على أنماط EEG وتطوير أدوات تشخيصية مصممة خصيصًا للسكان العرب.

هناك بعض القيود على هذه الدراسة التي يجب أخذها في الاعتبار. أولاً، كانت حجم العينة صغيرًا نسبيًا. ثانيًا، تم إجراء الدراسة في بيئة معملية، والتي قد لا تعكس الظروف الواقعية. ثالثًا، لم يتم تقييم أداء التقنية على الم

Recommended Academic Training

:Deepen your knowledge with these specialized courses from our Academy

أخلاقيات مهنة التعليمView Course → اصول التربية والتعليمView Course → التربية البيئية والتنمية المستدامةView Course →

Reference

Choudhary A.K. (2026). *Enhanced EEG-based detection of* major depressive disorder *using maximum likelihood estimation and machine learning*. Journal Of Big Data, 13(1).

DOI: 10.1186/s40537-026-01380-1

ARABPSYCHOLOGY.COM