

تعلم الآلة يتنبأ بالذهان المبكر بدقة عالية باستخدام بيانات متعددة.

تأليف

مدرس الدكتور محمد لوتي

مارس 28, 2026

اقتبس من هذا المقال

مدرس الدكتور محمد لوتي (2026). تعلم الآلة يتنبأ بالذهان المبكر بدقة عالية باستخدام بيانات متعددة.. عرب سايكولوجي. تم الاسترجاع من <https://arabpsychology.com/?p=120220>

تخيل أنك طبيب نفسي تحاول تشخيص حالة مراهق يعاني من تغيرات سلوكية مفاجئة. هل هي مجرد تقلبات مزاجية طبيعية للمراهقة، أم بداية مرض نفسي خطير مثل الذهان المبكر (Psychosis)؟ التشخيص المبكر والدقيق أمر بالغ الأهمية، لكنه يمثل تحدياً كبيراً نظراً لتداخل الأعراض مع اضطرابات أخرى.

منهجية البحث

قام باحثون بقيادة الدكتور زاكوفيتش بتصميم دراسة تهدف إلى استكشاف إمكانية استخدام تقنيات التعلم الآلي (Machine Learning) لتحسين دقة التشخيص المبكر للذهان. الذهان المبكر، الذي يظهر عادةً في أواخر سنوات المراهقة أو أوائل العشرينات، غالباً ما يكون صعب التشخيص بسبب تشابه الأعراض مع حالات أخرى. لتحقيق ذلك، جمع الفريق بيانات شاملة من 45 مريضاً يعانون من الذهان المبكر و 34 شخصاً سليماً من مركز طبي متخصص. تضمنت البيانات تحليلات لمستويات بعض البروتينات في الدم (مثل عامل التغذية العصبية المشتق من الدماغ - Brain-Derived Neurotrophic Factor أو BDNF، و proBDNF، ومستقبلات p75 العصبية، و S100B)، بالإضافة إلى نتائج اختبارات عصبية نفسية (Neuropsychometric tests) تقيس الوظائف الإدراكية مثل اتخاذ القرارات (Iowa Gambling Task)، وسرعة الاستجابة (Simple Response Time)، والذاكرة اللفظية (Zabor Verbal Task). كما تم جمع معلومات ديموغرافية (Clinicodemographic data) مثل العمر والجنس والتاريخ العائلي.

لم يكتفِ الباحثون بجمع البيانات، بل استخدموا أربع خوارزميات مختلفة للتعلم الآلي - الانحدار اللوجستي (Logistic Regression)، وآلة المتجهات الداعمة (Support Vector Machine)، والغابة العشوائية (Random Forest)، و XGBoost - لتدريب نماذج قادرة على التمييز بين المرضى والأصحاء. تم تدريب هذه الخوارزميات باستخدام مجموعات مختلفة من البيانات (البروتينات فقط، الاختبارات العصبية النفسية فقط، البيانات الديموغرافية فقط، مجموعات مختلفة من هذه البيانات) من خلال عملية تسمى "التحقق المتقاطع المتداخل" (Nested Cross-Validation) لضمان موثوقية النتائج. كما قاموا بتحسين أداء الخوارزميات من خلال تعديل "المعلمات الفائقة" (Hyperparameters) الخاصة بها.

النتائج

أظهرت النتائج أن خوارزمية XGBoost تفوقت على جميع الخوارزميات الأخرى في دقة التشخيص. عندما تم تدريبها على المجموعة الكاملة من البيانات (البروتينات، الاختبارات العصبية النفسية، والبيانات الديموغرافية)، حققت XGBoost دقة بلغت 91٪ (مع هامش خطأ $\pm 8\%$)، ودقة إيجابية (Precision) بلغت 92٪ (مع هامش خطأ $\pm 8\%$)، ومساحة تحت المنحنى (AUC أو Area Under Curve) بلغت 97٪ (مع هامش خطأ $\pm 4\%$). مساحة تحت المنحنى هي مقياس لمدى قدرة النموذج على التمييز بين الحالات الإيجابية والسلبية، وكلما اقتربت من 1، كانت القدرة أفضل.

تحليل "أهمية الميزات" (Feature Importance Analysis) كشف أن الاختبارات العصبية النفسية، وخاصة الأخطاء في مهمة Zabor Verbal Task ومعايير وقت الاستجابة، كانت الأكثر تمييزاً بين المرضى والأصحاء. كما أظهرت البروتينات المتعلقة بمسار عامل التغذية العصبية المشتق من الدماغ (BDNF pathway) أهمية كبيرة في التمييز بين المجموعتين. هذا يشير إلى أن التغيرات في هذه البروتينات قد تكون مؤشرات حيوية (Biomarkers) للذهان المبكر.

دلالات البحث

تشير هذه الدراسة إلى أن التعلم الآلي يمكن أن يكون أداة قوية لتحسين التشخيص المبكر للذهان. من خلال دمج بيانات

متنوعة من مصادر مختلفة، يمكن للنماذج القائمة على التعلم الآلي أن تتجاوز القيود المفروضة على التشخيص التقليدي الذي يعتمد بشكل كبير على التقييم السريري الذاتي. إن القدرة على تحديد المرضى المعرضين للخطر في مرحلة مبكرة يمكن أن تسمح بتقديم التدخلات العلاجية في الوقت المناسب، مما قد يحسن بشكل كبير من نتائجهم.

الأهم من ذلك، أن هذه الدراسة تؤكد على أهمية اتباع نهج متعدد الأوجه (Multimodal approach) في تشخيص الذهان. بدلاً من الاعتماد على نوع واحد من البيانات (مثل البروتينات أو الاختبارات العصبية النفسية فقط)، فإن دمج جميع المعلومات المتاحة يؤدي إلى دقة تشخيصية أعلى. هذا يفتح الباب أمام تطوير أدوات تشخيصية أكثر فعالية يمكن استخدامها في العيادات والمستشفيات، مما يساعد الأطباء على تقديم رعاية أفضل للمرضى الذين يعانون من الذهان المبكر.

Reference

Zakowicz P.T. (2025). *Machine learning helps predict early onset psychosis with serum protein biomarkers, neuropsychometry, and clinicodemographic data*. Scientific Reports, 16(1), 3662-3662

DOI: [10.1038/s41598-025-33765-2](https://doi.org/10.1038/s41598-025-33765-2)