

## الذكاء الاصطناعي وإدمان تعاطى المواد النفسية

شحاتة زيان\*

تقدم هذه الورقة عرضًا لما يمكن أن يقدمه الذكاء الاصطناعي في مجال تعاطى المواد النفسية المؤثرة في الأعصاب والتي تتسبب في حالة من الاعتماد، وقد عرضت الورقة للجهود التي يستخدم فيها الذكاء الاصطناعي، كما عرضت لظلال ذلك في العلوم الاجتماعية، وعرضت للتطورات المختلفة التي تتسارع بها الأبحاث في هذا السياق، كما عرضت لعلاقة الذكاء البشري العام والتطورات الحادثة في فهمه، مثل ما قدمه "دونالد هيب". كما عرضت لمراحل الكشف عن الأدوية ومتابعة استخداماتها في المجال الصحي العام، وفي مجال الإدمان على المخدرات والمواد الأخرى على وجه الخصوص. كما عرضت الورقة لعدد من النماذج التي استخدمت في الكشف، والتنبؤ بتعاطى المواد المختلفة كالقنب (الحشيش) والأفيون، وغيرهما، وانتهت الدراسة بعرض صورة المستقبل المأمول في هذا الشأن. والأمر المهم أن الباحث قام باستشهادات كبيرة من الأصول المذكورة لإزالة غموض الموضوع وتيسيره على القارئ.

**الكلمات المفتاحية:** تصنيف الأدوية، تصميم الأدوية، الذكاء الاصطناعي، الرعاية الصحية، استكشاف الأدوية، إدمان المخدرات، استعمال المواد النفسية المؤثرة في الأعصاب

### العلوم الاجتماعية وثقافة الذكاء الاصطناعي

إن الهدف من الوصول إلى تغطية شاملة لتفاعلات العلوم الاجتماعية في ظل ثورة الذكاء الاصطناعي، بدءًا من توظيف الأفراد، وطبيعة الوظائف، مرورًا بالتعليم والمهارات الرقمية الجديدة، وصولًا إلى التقنيات الآلية للحروب العسكرية ومستقبل الأخلاقيات؛ هو محاولة الجهات المختلفة تجسير الفجوة بين المتخصصين التقنيين والعلماء الاجتماعيين في موضوع الذكاء الاصطناعي؛ وبخاصة في ظل عالم الذكاء الاصطناعي المعولم، ومع اجتياح موجة التكنولوجيا الرقمية الهائلة للعالم؛ حيث يتغلغل الذكاء الاصطناعي بشكل متزايد في صميم حياتنا؛ من المساعدين الافتراضيين الشخصيين، وروبوتات الدردشة، إلى المركبات ذاتية القيادة، والروبوتات عن بُعد؛ حيث أصبح الذكاء الاصطناعي الآن جزءًا لا يتجزأ من حياتنا اليومية. إنه يُعيد تشكيل المجتمع والاقتصاد. وهو ما صرح به "كلاوس شواب"، مؤسس المنتدى الاقتصادي العالمي؛ بأن ثورة الذكاء الاصطناعي اليوم "لا تشبه أى شيء شهدته البشرية من قبل"، فالذكاء الاصطناعي ليس تقدمًا تكنولوجيًا بقدر ما هو تحول جذري في جميع التقنيات

\* أستاذ علم النفس، المركز القومي للبحوث الاجتماعية والجنائية.

أو أنه يمثل الثورة الصناعية الرابعة، وأن التغييرات عميقة لدرجة أنه من منظور التاريخ البشرى لم يكن هناك وقت أكثر وعدًا، أو خطرًا محتملاً، ومع ذلك؛ فإن ما يقلق هو أن صناع القرار غالبًا ما يكونون عالقين فى التفكير التقليدى الخطى، أو منغمسين جدًا فى الأمور المباشرة، فنحن بحاجة إلى التفكير بشكل استراتيجى حول قوى التغيير والابتكار التى تشكل مستقبلنا.

ويرى "شواب" أن بعض الأكاديميين والمهنيين يعتبرون التطورات التى يتناولها مجرد جزء من الثورة الصناعية الثالثة. ومع ذلك؛ فهناك ثلاثة أسباب تُعزز قناعته بأن ثورة رابعة مُستقلة قيد التنفيذ؛ السرعة: خلافًا للثورات الصناعية السابقة، تتطور هذه الثورة بوتيرة متسارعة لا خطية، وهذا نتيجة لعالمنا متعدد الأوجه والمتربط بعمق، ولأن التكنولوجيا الجديدة تُؤدّد تكنولوجيا أحدث وأكثر كفاءة؛ الاتساع والعمق: يعتمد هذا النهج على الثورة الرقمية، ويجمع بين تقنيات متعددة تُحدث تحولات جذرية غير مسبوقة فى الاقتصاد والأعمال والمجتمع والأفراد، فهو لا يُغير فقط "ماهية" و"كيفية" القيام بالأشياء؛ بل يغير أيضًا "هويتنا"؛ تأثير النظم: يتضمن تحويل الأنظمة بأكملها، عبر (وداخل) البلدان والشركات والصناعات والمجتمع ككل. (Klaus Schwab, 2016)

فقد أدت التطورات التكنولوجية الحديثة إلى إحداث تحولات جذرية فى قطاع التصنيع والخدمات ومنصات الأعمال من خلال الذكاء الاصطناعى المتقدم، مما أثر بشكل كبير على معظم الوظائف، بما فى ذلك العديد من المهن التى تبدو بمنأى عن الاضطراب الرقمية، وتشير تقديرات الأبحاث فى الولايات المتحدة والمملكة المتحدة واليابان وأستراليا، بما فى ذلك المراجعات الأكاديمية والاستفسارات الحكومية، إلى أن ما يقرب من ٤٠٪ إلى ٥٠٪ من الوظائف الحالية معرضة للخطر بسبب تكنولوجيا الذكاء الاصطناعى والأتمتة Automation خلال الخمسة عشر إلى العشرين عامًا المقبلة، ويشير باحثون آخرون إلى اتجاه متزايد نحو استقطاب الوظائف المصاحب للأتمتة، وفى الوقت نفسه؛ تشير التقديرات إلى أن الذكاء الاصطناعى قد يسهم بنحو ١٦ تريليون دولار فى الاقتصاد العالمى بحلول عام ٢٠٣٠. ويذكرنا (أنتونى إليوت) بأن أى اعتبار قوى ومستتير نظريًا لرقمنة الأنظمة التكنولوجية والاجتماعية يجب أن يستند إلى سبع مجموعات من الاعتبارات، هذه الاعتبارات تُعدّ أساسية لفهم أنظمة الذكاء الاصطناعى المعقدة، هى:

أولاً، الحجم الهائل لأنظمة الرقمنة، والأتمتة التكنولوجية، والعلاقات الاجتماعية التى تتداخل مع الذكاء الاصطناعى- وجميعها عوامل تمكين عالمية رئيسية لاقتصاد البيانات الرقمية؛ ثانيًا، الذكاء الاصطناعى ليس "تقنية جديدة" تتجاوز ببساطة التقنيات السابقة أو تُلغىها؛ بل تستوعبها وتزيد عليها؛ ثالثًا، علينا أن ندرك أن الانتشار العالمى للذكاء الاصطناعى مُدمج فى أنظمة تكيفية مُعقدة. فبينما

تزامن ظهور شبكات الاتصالات المُعقدة مع ظهور التصنيع، لم يكن ذلك إلا في أواخر القرن العشرين وأوائل القرن الحادى والعشرين؛ رابعًا، الانتشار الواسع للذكاء الاصطناعى. وهنا يشار إلى مختلف الأنظمة الرقمية المعقدة والمترابطة، والتي تنقل المعلومات الرقمية وترمزها وتقرزها وتعيد توجيهها (تقريبًا) فى كل مكان، وبشكل أن عبر الشبكات العالمية؛ خامسًا، زيادة تعقيد هذه الأنظمة التي تُنظَّم وتُعيد تنظيم الحياة الرقمية، وقد ساهم هذا التعقيد المتزايد فى صعود الحوسبة والذكاء الاصطناعى فى كل مكان، وعززته معدلات هائلة من التحولات التكنولوجية والاجتماعية المرتبطة بها؛ سادسًا، التغلغل الكبير فى تقنيات الذكاء الاصطناعى فى صميم التجربة المعيشية، وفى نسيج الذات البشرية، والحياة الشخصية، والهويات الثقافية، فالأنظمة الرقمية التكيفية المعقدة والبنى التحتية التكنولوجية ليست مجرد عمليات أو أحداث "خارجية"؛ بل هى مُركزة فى العلاقات الاجتماعية ونسيج حياة الناس؛ أى أن الأنظمة الرقمية المعقدة تُؤد أشكالًا جديدة من العلاقات الاجتماعية، وتُعيد تشكيل عمليات تكوين الذات والهوية الشخصية؛ وأخيرًا، سابعًا، تتضمن التغيرات التكنولوجية الناتجة عن ظهور الأنظمة الرقمية المعقدة عمليات تحول فى المراقبة والسلطة، تختلف تمامًا عن أى شىء حدث سابقًا. (Anthony Elliott, 2022)

### **علاقة الذكاء العام بالذكاء الاصطناعى وما يثيره من مشكلات فكرية ومنهجية**

كان لعالم النفس "دونالد هب" مساهمة قيمة ذكرها فى كتابه "تنظيم السلوك" فى عام ١٩٤٩، وفى كتابه قَدَم فيه مفهومى اللدونة المشبكية synaptic plasticity والتجمعات الخلوية، مُقدّمًا بذلك نظريةً للأساس العصبى الفسيولوجى للسلوك، وقد أثرت أفكار "هيب" على جميع مجالات علم النفس وعلم الأعصاب. (Donald Hubb, 1949)

وغالبًا ما يُعرف "دونالد هيب" بأنه "أبو علم النفس العصبى" لعمله فى دمج عالمى علم النفس وعلم الأعصاب، وقد تحقق ذلك إلى حد كبير من خلال عمله الرائد "تنظيم السلوك The Organization of Behavior: نظرية فى علم النفس العصبى"، الذى نُشر عام ١٩٤٩، كانت فكرة "هيب" الرائدة هى أن علم النفس بحاجة إلى التكامل بشكل أوثق مع علم الأعصاب وعلم وظائف الأعضاء لتفسير السلوك البشرى، وقد أدى ذلك إلى دمج "العقل" المجرى الذى ركز عليه علم النفس مع وظائف الدماغ الفيزيائية والبيولوجية، وقد برهن "هيب" بأن هذا النهج ضرورى للنظر إلى علم النفس كتخصص علمى، وقد حاول فى كتابه الجمع بين عدد من خطوط البحث المختلفة، فى نظرية عامة للسلوك تحاول سد الفجوة بين علم وظائف الأعصاب وعلم النفس، وكذلك الفجوة بين علم النفس المعملى ومشكلات العيادة، وقد كتب كتابه "منظمات السلوك، نظرية نفس عصبية" للعديد من التخصصات على أمل أن يكون تطوير النظرية

النفسية شأنًا تعاونيًا، وكثيرًا ما كان ذلك في الماضي شاهدًا على ذلك مثلما حدث مع كل من: "هيلمهولتز" و"جاكسون" و"بافلوف" و"فرويد"، وكثيرًا ما يكون لدى الطبيب السريري وعالم وظائف الأعضاء إمكانية الوصول المباشر إلى البيانات ذات الأهمية الأولى لعلم النفس، وأحيانًا دون إدراك هذه الحقيقة. (Hebb, D. O. 1994)

وعلى إثر ذلك ظهرت طفرة في الدراسات التي تبنت النهج الذي ابتكره "هيب" كونه قدم أسلوبًا يجمع بين العلمية والعملية في تفسير عملية التعلم المعقدة مستندًا على الخلفية البيولوجية لعمل الدماغ البشري، وهو ما يستند إليه رواد الذكاء الاصطناعي من علماء الرياضيات، وأظهر ميلًا لديهم لمحاكاة الدماغ البشري في تعامله مع المشكلات البسيطة منها والمعقدة؛ حيث بدأ كل شيء بداية من "اختبار تورينج" Alan Turing. في شكل لعبة تقليد؛ حيث تجتاز الآلة الاختبار إذا لم يتمكن المُقيّم البشري في المحادثة من التمييز بينها وبين الإنسان في المحادثة، ويمكن أن يكون المعادل لهذا في الرعاية الصحية هو الطبيب والنظام المدعوم بالذكاء الاصطناعي لتشخيص نفس المشكلة الصحية بناءً على المحادثة أو بيانات الرعاية الصحية. وعلى الرغم من أن معظم الأنظمة التي تعمل بالذكاء الاصطناعي حتى الآن إما لم تجتز الاختبار أو حاولت خداع المُقيّم البشري في توليد أفضل النتائج، أو اجتازت الاختبار؛ فإن الأمر المثير للقلق هو أن تطبيق مثل هذه المبادئ غير مستحسن ولا مستدام في الرعاية الصحية؛ حيث تتطلب الأنظمة المهمة للمهام مثل الرعاية الصحية أقصى درجات الدقة والتحديات المتنوعة التي قد تكون بسبب القيود التكنولوجية أو المخاوف الأخلاقية أو السريية. والهدف هنا هو النظر في الجوانب المحتملة المتعلقة بالتحيزات الخوارزمية وعدم اكتمال البيانات بالتفصيل. (J. Michael Innes and Ben W. Morrison, 2022)

### **تطور أنظمة الذكاء الاصطناعي**

وقد تطورت أنظمة الذكاء الاصطناعي؛ حيث بدأ كل شيء بالذكاء الاصطناعي الرمزي؛ حيث ينشئ الخبير مجموعة من القواعد لترميز كيفية التصرف في موقف معين. وتتناسب قدرة النظام بشكل مباشر مع القواعد التي يشفرها الخبير. ومن الواضح أن هذا حد من وظائف النظام ولكنه قدم فهمًا واضحًا لسبب اتخاذ النظام لقرار معين. وكانت هذه الأنظمة تعين قيمة المتغير إما صحيح أو خطأ (0 أو 1)، ولكن من الناحية العملية، من الصعب الحصول على أى قيمة مطلقة لمثل هذه المتغيرات، على سبيل المثال، درجة مرض المريض. أدى هذا إلى ظهور الموجة الثانية من أنظمة الذكاء الاصطناعي القائمة على المنطق الضبابي الذي يسمح للمتغير بأخذ أى قيمة بين 0 و 1. ساعدت هذه الأنظمة في توسيع

نطاق أنظمة الجيل الأول المناسبة للمشاكل المعقدة قليلاً، لكنها فشلت في الاستجابة لاحتياجات الساعة  
أى ذكاء الطبيب البشرى الحقيقى (Blagoj et al. 2020).

ولقد برز التعلم الآلى القائم على البيانات فى المقدمة؛ حيث تعمل الخوارزمية باستمرار على  
تحسين أدائها دون أى تشفير مباشر للخبرة؛ حيث يتم تطوير الشبكات العصبية الاصطناعية (ANNs)  
والتعلم الآلى (ML) لتوجيه أنظمة الذكاء الاصطناعى الحقيقية حالياً فى جميع المجالات بما فى ذلك  
الرعاية الصحية، وتحاول الشبكات العصبية الاصطناعية محاكاة الدماغ البشرى، وتتكون بشكل عام من  
طبقة إدخال وطبقة إخراج وطبقة مخفية.

يتم إعطاء الإدخال لطبقة الإدخال التى يتم تمريرها إلى الطبقة المخفية التى تحتوى على الخلايا  
العصبية، والتى تمر بعد ذلك إلى الإخراج عبر طبقة الإخراج. وتتخذ الخلايا العصبية فى الطبقة  
المخفية القرار وعدد الخلايا العصبية فى الطبقة المخفية يتناسب بشكل مباشر مع تعقيد المشكلة  
المطروحة لحلها. يتعلق الأمر كله بتصميم بنية الطبقة المخفية، وقد تكون هناك طبقات متعددة بها  
ملايين الخلايا العصبية، وهنا قد يحتاج الخبير إلى ساعات لتدريب الخلايا العصبية على الإخراج  
المطلوب، لكن التعلم الآلى يأتى فى دور تدريب الخلايا العصبية بناءً على البيانات، وهى مهمة لا  
تنتهى تقريباً مثل التعلم البشرى. (Pulkit Verma, Hemant Kushwaha, and Harpreet Singh, 2023)

### **لماذا نحتاج إلى تقنيات الذكاء الاصطناعى لمعالجة البيانات الصحية؟**

فى الأيام التى كانت تُجمع فيها البيانات الطبية بتتسيق ورقى تناظرى، كان لتقييم البيانات قيود واضحة؛  
حيث لم تكن هناك ببساطة آلية لتقييمها على نطاق أوسع. لقد تغير هذا بشكل جذرى مع إدخال  
التتسيقات الرقمية. أولاً، يمكن تخزين تتسيقات البيانات الرقمية بسهولة أكبر بكثير وفى مساحات أصغر  
بكثير، ثانياً، مع العديد من الأجهزة القابلة للارتداء، يمكن جمع البيانات الطبية بثروة لم يكن من الممكن  
تصورها فى العصر التناظرى. اليوم، على سبيل المثال، تقيس ساعات اليد بالفعل معدل نبضنا ويمكنها  
اكتشاف عدم انتظام ضربات القلب، ويمكن توثيق ملف تعريف حركتنا على مدار اليوم، ويمكن حتى  
مراقبة جودة نومنا فى الليل بواسطة هذه الأجهزة القابلة للارتداء. ونتيجة لذلك؛ تم إنتاج وبيع ما يقرب  
من نصف مليار جهاز قابل للارتداء فى الأشهر القليلة الأولى من جائحة كوفيد-19. وتستمر هذه  
السوق فى النمو بشكل كبير. (industry/com.randviewresearch)

ومع ذلك؛ لم يُطرح فى السوق حتى الآن سوى عدد قليل من هذه التطبيقات كمنتجات طبية  
معتمدة. والسبب فى ذلك هو أن عمليات اتخاذ القرار الطبى مرتبطة بالنتائج التى تُنتجها تطبيقات تلك

البرامج الرقمية. وهذا، يتطلب موافقة الجهات التنظيمية كالأجهزة الطبية المرخصة، وهذا بدوره يتطلب اختبارات مكثفة في التجارب السريرية في عمليات موافقة معقدة ومكلفة تحددها الجهات التنظيمية للأجهزة الطبية قبل طرحها في السوق. إلا أن جائحة كوفيد-19 سلطت الضوء على المزايا العديدة لجمع البيانات الصحية على نطاق واسع بواسطة الأجهزة القابلة للارتداء وغيرها من الأجهزة. فعلى سبيل المثال، أصبح من الواضح فجأة أن الإحالة الطارئة للمرضى المصابين بعدوى فيروس كورونا المستجد (2-CoV-SARS) يمكن أن تصبح أسهل وأفضل بكثير من خلال قياس مستويات الأكسجين في الدم ومعدل ضربات القلب باستخدام أجهزة صغيرة قابلة للارتداء. وكان من شأن ذلك أن يؤدي إلى خيارات إحالة طارئة من شأنها أن تُخفف العبء بشكل كبير على أقسام الطوارئ في المستشفيات. وبالمثل؛ كان من الممكن لتقييم الصور الشعاعية باستخدام إجراءات الذكاء الاصطناعي أن يُحدد فوراً التشخيص المشتبه به لمرض كوفيد-19. وبالتالي؛ بات من الواضح منذ زمن طويل أن معالجة البيانات الصحية القائمة على الذكاء الاصطناعي يمكن أن تُخلص إلى استنتاجات بالغة الأهمية لكلٍ من الأفراد المرضى المتأثرين، والسكان ككل، وهو ما كان من المستحيل تصوره في الماضي. (Magnus Von Knebel Doeberitz, 2022)

ومع حدوث التطورات الكبيرة برز دور الآلية التي تيسر عمل المبرمجين والرياضيين والتي تتمثل هنا في الخوارزمية؛ فهي الآلية الأساسية للتعامل مع البيانات والعمل على جعلها مؤتمتة Automated، فما هي خوارزمية الذكاء الاصطناعي؟ تعرف الخوارزمية بأنها "مجموعة من التعليمات التي يجب اتباعها في العمليات الحسابية أو غيرها من العمليات". وهذا ينطبق على كل من الرياضيات وعلوم الكمبيوتر، لذا؛ على المستوى الأساسي؛ فإن خوارزمية الذكاء الاصطناعي هي البرمجة التي تخبر الكمبيوتر كيف يتعلم كيفية العمل من تلقاء نفسه. وبالطبع؛ خوارزمية الذكاء الاصطناعي أكثر تعقيداً بكثير مما يتعلمه معظم الناس في علم الجبر، فهناك مجموعة معقدة من القواعد التي تقود برامج الذكاء الاصطناعي، وتحدد خطواتها وقدرتها على التعلم، ومن دون "خوارزمية"؛ لن يكون للذكاء الاصطناعي وجود. (<https://www.tableau.com/data-insights/ai/algorithms>)

ومن هنا بدأ الذكاء الاصطناعي يتغلغل في جميع المجالات في جميع أنحاء العالم، والرعاية الصحية ليست استثناءً، ونظراً لكم الهائل من العائدات على الاستثمار في أنظمة الذكاء الاصطناعي المطورة للرعاية الصحية؛ فإن هناك قدرًا هائلاً من الاستثمارات جارية، ورغم أنه لا يمكن تجاهل القفزات الكبيرة في تطبيق الرعاية الصحية؛ فإنه يجب التعامل مع تطبيق الذكاء الاصطناعي على وجه التحديد في المجالات المهمة مثل الرعاية الصحية بحذر. تقدم هذه الورقة رؤى حول التحيزات الكامنة المحتملة

وعدم العدالة وعدم المساواة في خوارزميات الذكاء الاصطناعي. المخاوف المتعلقة بجودة البيانات ومجموعات البيانات التدريبية. يمكن أن يكون التحيز الكامن راجعاً إلى أسباب عديدة تتمثل في التفضيلات الخفية أو مجموعات البيانات غير الممثلة/غير المكتملة.

### **الذكاء الاصطناعي والتحيز في المجال الصحي**

وقد أثار (Verma, Kushwaha, and Harpreet Singh, 2023) عند مناقشة الذكاء الاصطناعي في الطب وجوانب الرعاية الصحية حيث يتعين على مثل هذه الأنظمة اتخاذ قرارات تغير الحياة، فمن الضروري مناقشة عدالة مثل هذه الأنظمة تجاه المرضى. إذ تعنى العدالة في مثل هذه الأنظمة أن الأنظمة تتخذ القرارات دون أى تحيز ومعرفة محدودة بناءً على مجموعات البيانات المحدودة. ويكشف الفهم الشامل للمفهوم والأنظمة أن التحيز المتأصل والنتائج غير العادلة من مثل هذه الأنظمة تنشأ إما بسبب التحيز في البيانات أو في الخوارزميات (Mehrabani et al. 2019)، وستؤدي التحيزات في البيانات إلى جعل الخوارزمية غير المتحيزة تعمل بشكل سيئ على معايير العدالة والبيانات غير المتحيزة عند استخدامها بواسطة الخوارزمية المتحيزة لن تعمل بشكل أفضل أيضاً على جبهة العدالة. قد تختلف درجة الصلابة في العدالة من حالة إلى أخرى، لكنها غير مقبولة على الإطلاق في حالة الرعاية الصحية، فليس من الممكن دائماً وضع علامة على التحيز إما في بيانات التدريب أو البيانات الخوارزمية، ففي بعض الأحيان قد يتطلب التحيز في أحدهما تحيزاً في الآخر لإبطال النتيجة الناتجة.

وقد ناقش الباحثون المناطق الرمادية المحتملة فيما يتعلق بالتحيزات المتأصلة في خوارزمية الذكاء الاصطناعي في الرعاية الصحية. فهناك حاجة إلى نهج متعدد الأبعاد لتصحيح التحيزات في مجموعات بيانات التدريب والخوارزميات والسلوك البشري أيضاً. على الرغم من أن أنظمة الذكاء الاصطناعي تظهر خصائص متحيزة؛ فإن هذا لا يعنى أنه باعتبارنا ممارسين للرعاية الصحية أو مطورين لأنظمة الذكاء الاصطناعي، نحتاج إلى تثبيط استخدام أنظمة الذكاء الاصطناعي في الرعاية الصحية، نحن بحاجة إلى فهم أن أنظمة الذكاء الاصطناعي تظهر تحيزاً لأن مجموعات البيانات في العالم الحقيقي التي تم تطوير النظام عليها متحيزة بطبيعتها. علاوة على ذلك؛ يكمن الحل في قبول التحيزات المتأصلة في أنظمة الذكاء الاصطناعي ومعالجتها من خلال نهج منهجي لجعل أنظمة الذكاء الاصطناعي أكثر عدالة من خلال خوارزميات عادلة وبيانات عادلة، يجب أن تكون الجهود لتقليل التحيز من خلال معالجة غالبية التحيز الخوارزمي والبيانات والذهاب خطوة أبعد من خلال استخدام الذكاء الاصطناعي للحد من التحيز/الظلم في الرعاية الصحية.

(Pulkit Verma, Hemant Kushwaha, and Harpreet Singh, 2023)

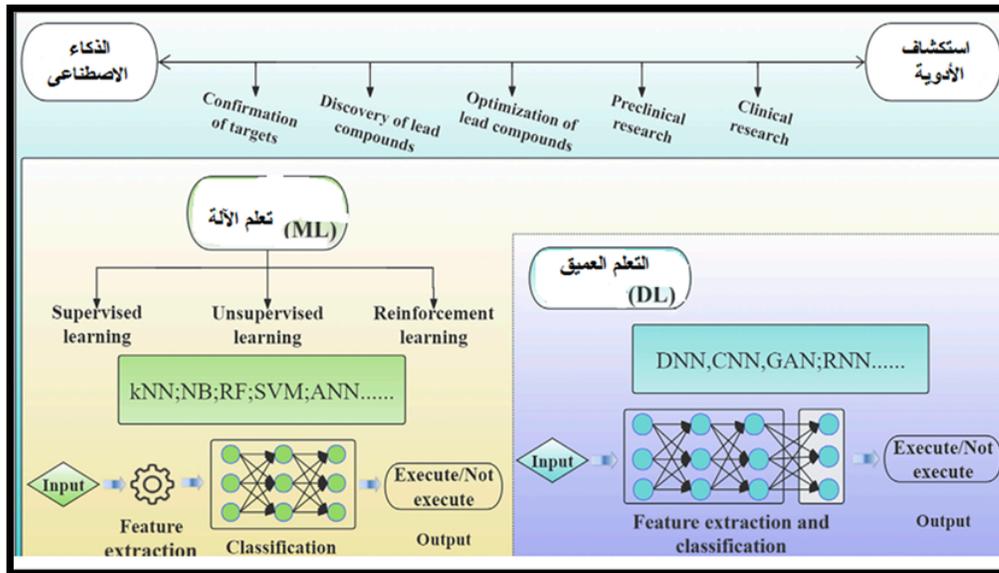
ونظرًا لأن الذكاء الاصطناعي هو من الابتكارات التي لا تُحدث ثورة في العمليات الصناعية فحسب؛ بل أيضًا في الطريقة التي نعيش بها ونتفاعل بها مع بعضنا البعض، تعمل هذه التغييرات؛ وبخاصة التغييرات في الذكاء الاصطناعي، على إحداث ثورة في كيفية إجراء البحوث مما يسمح لنا بتحليل مجموعات البيانات الضخمة للغاية بكفاءة أكبر وتحليل بيانات أكثر تنوعًا وتعقيدًا والتي كانت تعتمد سابقًا على التعليقات البشرية (على سبيل المثال، التعليق على الصور والفيديو والنصوص والبيانات الصوتية لمعرفة ما إذا كان الكحول موجودًا أو كيفية تصوير تعاطي المخدرات)، فيجب أن تسمح لنا هذه التغييرات بابتكار حلول المشكلات التي كانت تُرى سابقًا على أنها معقدة للغاية أو كبيرة جدًا بحيث لا يمكن حلها وتسمح لنا بالإجابة على أسئلة بحثية جديدة ومثيرة.

### **الذكاء الاصطناعي واستكشاف الأدوية وتفاعلاتها وتأثيراتها**

يلعب الذكاء الاصطناعي دورًا كبيرًا في فحص الأدوية وتصميمها والتجارب السريرية، فمن بين أهم الإنجازات التي يحققها الذكاء الاصطناعي مجال تطوير الأدوية الجديدة واكتشاف المركبات الرئيسية للأدوية وتحسينها، وهي عملية طويلة ومكلفة وعالية المخاطر. يمكن أن يستغرق تحويل دواء جديد من مرشح واعد إلى منتج قابل للتسويق أكثر من عقد، بتكلفة تصل إلى مليار دولار، ويؤدي إلى ارتفاع معدل الفشل السريري، وفي الوقت الحالي، تؤثر أمراض مثل السرطان والسكري ومرض الزهايمر ومرض باركنسون بشكل كبير على صحة الإنسان وأصبحت مشكلة صحية عامة خطيرة على مستوى العالم، مما يجعل اكتشاف الأدوية وتطويرها أمرًا بالغ الأهمية، وقد اعتمدت شركات تطوير الأدوية أساليب مختلفة للتغلب على هذه المعضلة؛ حيث يلعب الذكاء الاصطناعي دورًا رئيسيًا. على سبيل المثال؛ كشفت دراسة أجرتها شركة التكنولوجيا Tech Emergence أن تطبيق الذكاء الاصطناعي على تطوير الأدوية الجديدة يمكن أن يسرع العملية بنسبة ٢٪، وتوقع تقرير صادر عن Goldman Sachs أنه مع نضوج تكنولوجيا الذكاء الاصطناعي، يمكن أن تصل المدخرات السنوية في مجال تطوير الأدوية الجديدة إلى ٢٨ مليار دولار، كما بلغ عدد الأدوية المبتكرة المعتمدة في سوق الأدوية في الصين ١٤ و ٢٤ و ١٨ و ٣٧ و ٤٩ و ٤٨ و ٤٧ بين عامي ٢٠١٤ و ٢٠٢٠، مع زيادة عدد الأدوية المبتكرة المنتجة محليًا من ٠ في عام ٢٠١٧ إلى ١٤ في عام ٢٠٢٠ (Tang et al., 2022). تُعزى هذه الأرقام إلى التأثير الذي لا يمكن إنكاره للذكاء الاصطناعي على هذه العملية، مما يشير إلى أنه من المتوقع أن يُحدث الذكاء الاصطناعي ثورة في تطوير الأدوية.

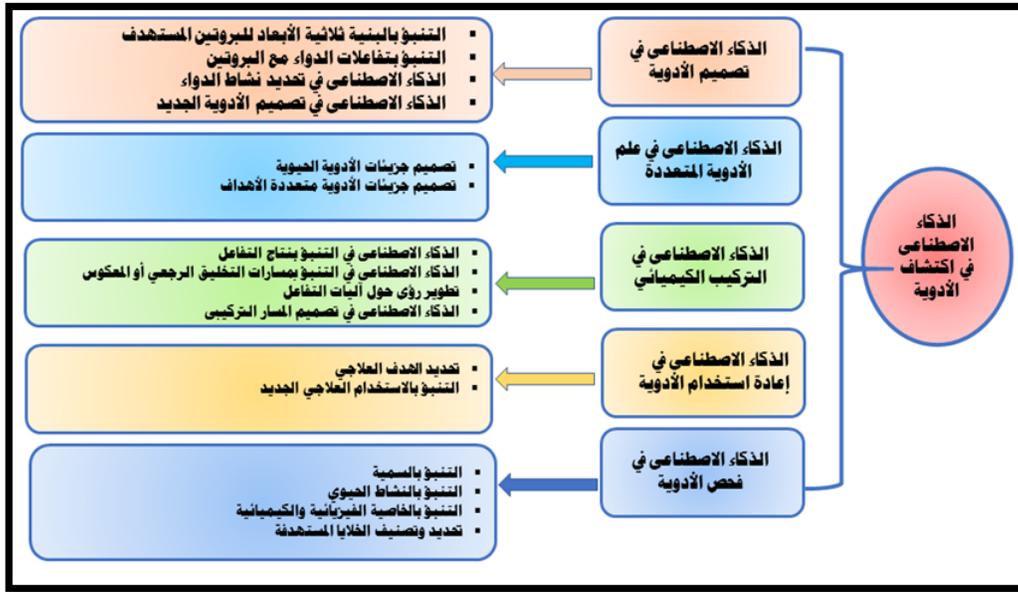
تشتمل خوارزميات التعلم الآلي التقليدية الأكثر شيوعًا في اكتشاف الأدوية وتطويرها خوارزميات (Nearest Neighbors (k-NN)، والمصنف البايزي البسيط (NB)، والغابات العشوائية (RF)، وآلة الدعم المتجهي (SVM)، والشبكات العصبية الاصطناعية (ANNs). وقد تم تلخيص أدوارها في اكتشاف الأدوية وتطويرها.

شكل (١) التالي يظهر نظرة عامة على تطبيقات وتقنيات الذكاء الاصطناعي في مجال اكتشاف الأدوية. يشمل استخدام الذكاء الاصطناعي في اكتشاف الأدوية تطبيقات وتقنيات متنوعة. يتضمن دمج الذكاء الاصطناعي في اكتشاف الأدوية دمج التعلم الآلي والتعلم العميق؛ حيث يُعد التعلم العميق جزءًا منه. يُصنف التعلم الآلي أيضًا إلى ثلاثة أنواع رئيسية: التعلم المُشرف، والتعلم غير المُشرف، والتعلم المُعزز. يوضح هذا الشكل أيضًا خوارزميات التعلم الآلي والتعلم العميق، مُبرزًا الاختلافات في منهجيات تنفيذها. (Yuyuan Wu, et. al. 2024).



شكل (١) نظرة عامة على تطبيقات وتقنيات الذكاء الاصطناعي في مجال اكتشاف الأدوية. (Yuyuan Wu, et.al. 2024).

وبشكل أكثر تفصيلاً يعرض الشكل (٢) التالي عرض دور الذكاء الاصطناعي في اكتشاف الأدوية. إذ يُمكن استخدام الذكاء الاصطناعي بفعالية في جوانب مُختلفة من اكتشاف الأدوية، بما في ذلك تصميم الأدوية، والتركيب الكيميائي، وفحص الأدوية، وعلم الأدوية المتعددة، وإعادة استخدام الأدوية. وتتشكل فيه الأدوار المختلفة التي يلعبها الذكاء الاصطناعي في مختلف مراحل اكتشاف الأدوية؛ تركيبها، وفحصها، وتقييمها.



شكل (٢) يعرض دور الذكاء الاصطناعي في اكتشاف الأدوية.

(Debleena Paulz, et. al., 2021)

### نظرة عامة على الدراسات التي تستخدم التعلم الآلي في أبحاث تعاطي المخدرات

وفقًا لمنظمة الصحة العالمية، كان هناك مليارًا متعاطي كحول، و١,٣ مليار مدخن، و١٨٥ مليون متعاطي مخدرات في عام ٢٠٠٠. وقد ساهم هذا الرقم في ١٢,٤٪ من جميع الوفيات في جميع أنحاء العالم في ذلك العام، لا يُميز الإدمان بين الجنسين، وجميع الأعراق، وجميع الأعمار. ومع ذلك؛ فإن أعلى معدل للإدمان هو في فئة المراهقين والشباب (الذين تتراوح أعمارهم بين ١٢ و ٢٩ عامًا) (مكتب الأمم المتحدة المعنى بالمخدرات والجريمة، ٢٠١٢). إن ارتفاع معدل بدء تعاطي المواد المخدرة خلال هذه الفترة لديه القدرة على تغيير طبيعة تطور الدماغ؛ نظرًا لأن هذه الفترة العمرية هي التي يمر فيها الدماغ بعمليات نضج حاسمة. واسترشادًا بالبحوث متعددة التخصصات في علم الأعصاب، وعلم الأوبئة، وتصوير الدماغ، وعلم الوراثة، يُفهم الآن أن الإدمان مرض دماغي نظرًا للتغيرات التي يحدثها فيه. ومثل أمراض الدماغ الأخرى، يُوصف الإدمان على أفضل وجه باستخدام ثلاثة عناصر أساسية: الانتشار، والاستمرار، وأنه مرض، الإدمان منتشرٌ في جميع جوانب حياة الفرد، وهو مُستمرٌّ إذ تستمر آثاره رغم جهود الفرد. وأخيرًا؛ يُعدّ الإدمان مرضيًا لأن آثاره لا يمكن السيطرة عليها، وبالتالي، فإنّ البحث القهري عن المخدرات والاستمرار في تعاطيها رغم عواقبها السلبية يُميزان الإدمان بشكلٍ عام، ومن منظورٍ سريري، يُشخّص الإدمان رسميًا من خلال مقابلة سريرية باستخدام إرشاداتٍ مثل الدليل

التشخيصي والإحصائي للاضطرابات العقلية، حاليًا في طبعته الخامسة (DSM-5) الصادر عن الجمعية الأمريكية للطب النفسي، أو التصنيف الدولي للأمراض (ICD) الصادر عن منظمة الصحة العالمية. ووفقًا للدليل التشخيصي والإحصائي للاضطرابات العقلية (DSM-5)؛ فإن الإدمان مرضٌ متدرج مُزمنٌ ذو أنماط سلوكية مُتفاوتة الشدة. ولذلك؛ يُشير الدليل التشخيصي والإحصائي للاضطرابات العقلية (DSM-5)، الذي طُبّق عام ٢٠١٤، إلى هذا الطيف الواسع باسم "اضطرابات تعاطي المواد" (SUDs). (Filbey, F. M., 2019,1-2)

وقد قدر تقرير المخدرات العالمي ٢٠٢٣ أن متعاطي القنب يقدر بـ ٢١٩ مليون شخص في عام ٢٠٢١، وهو ما يمثل ٤٪ من سكان العالم، كما أن متعاطي القنب زاد في العقد الأول من القرن الحادي والعشرين بنسبة ٢١٪، ويمثل القنب حصة كبيرة من الأضرار المرتبطة على مستوى العالم لارتفاع معدل تعاطيه؛ حيث قدر تعاطيه بنسبة ٤١٪ عام ٢٠١٩، و٤٦٪ في عام ٢٠٢١. ولا يزال القنب هو المخدر الرئيسي الذي يثير قلق غالبية الأشخاص الذين يتلقون العلاج في إفريقيا. ويقدر عدد متعاطي المؤثرات الأفيونية في عام ٢٠٢١ بـ ٦٠ مليون شخص، بما يمثل ١,٢٪ من سكان العالم، وظل المستوى العالمي للمؤثرات الأفيونية مستقرًا في عام ٢٠٢١، بعد زيادة سابقة في عامي ٢٠١٧، ٢٠١٩. ويشير التقرير إلى أن المساحات الإجمالية المزروعة بخشخاش الأفيون على الصعيد العالمي بنسبة ٢٨٪ في عام ٢٠٢٢، وانخفض إنتاج الأفيون بنسبة ٣٪. ولكن الاتجاه الطويل الأمد لا يزال تصاعديًا. كما قدر عدد متعاطي المنشطات الأمفيتامينية في عام ٢٠٢١ بـ ٣٦٪ بما يمثل ٠,٧٪ من سكان العالم، وتشير التقييمات إلى زيادة الأمفيتامينات في عام ٢٠٢١ وما سبقها من أعوام؛ حيث قدر عدد متعاطي الإكستاسي وحده في عام ٢٠٢١ بـ ٢٠ مليونًا بما يمثل ٠,٤٪ من سكان العالم. كما وجه التقرير النظر إلى أن هناك اتجاهًا نحو استخدام العديد من سلائف البروبانول والابتعاد عن استخدام الأفيون وغيرها المنتشرة فعلاً. (تقرير المخدرات العالمي، ٢٠٢٣)

### **الآليات العصبية لإدمان المخدرات وكيفية تعامل الذكاء الاصطناعي معها**

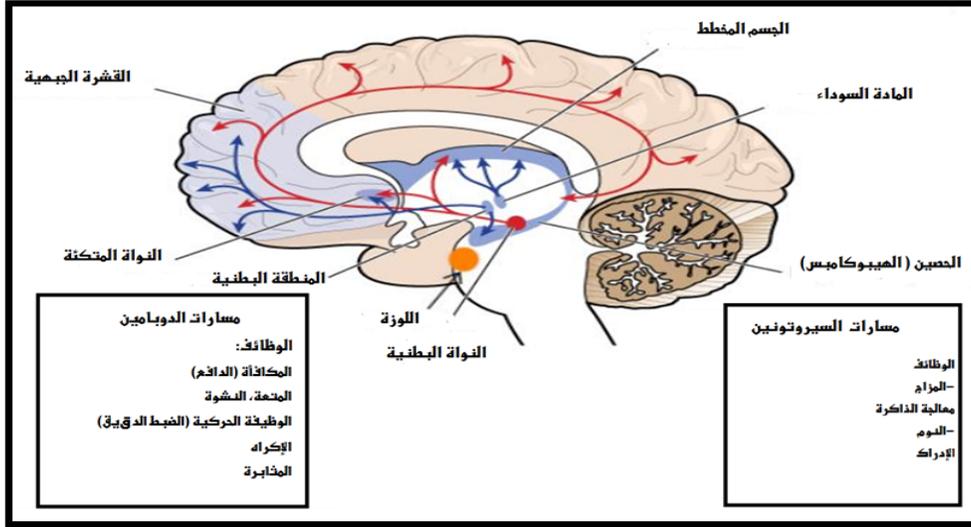
وعلى المستوى العصبى يؤدي التعاطي المستمر للمخدرات إلى تغييرات عصبية حيوية؛ وبخاصة داخل المناطق الدماغية المعنية بالمكافأة والتعلم والذاكرة والتحكم المعرفى. ويمكن تسخير الآليات المحتملة لإدمان المخدرات، بما فى ذلك الاضطراب فى اللدونة المشبكية ومسارات إشارات أنزيمات الكيناز (عملية الإمداد بالفوسفور)، من خلال الذكاء الاصطناعي لتحقيق التوازن بين آليات القشرة الحوفية المكافئة والنفور دون المبالغة فى الحالات الذهانية. وفى استخدام تقييم الإمكانيات الإدمانية؛ حيث يكون الذكاء الاصطناعي مفيدًا لاكتشاف السمات المهمة فى حركية الأدوية ودينامياتها والعمليات الدوائية التى

تسير بها المواد المختلفة في الجسم ADME، وكذلك في تحديد المخاطر في مجموعات محددة من المرضى.

هذا ويلعب المخطط الظهري Dorsal striatum، وهو جزء من العقد القاعدية Basal ganglia، دورًا حاسمًا في تطور إدمان المخدرات والحفاظ عليه. وهو يشارك بشكل كبير في تكوين العادات والانتقال من تعاطي المخدرات الطوعي إلى سلوك البحث القهري عن المخدرات من خلال النقل العصبي المتغير والمرونة العصبية، ومن المقترح بعد ذلك أن تصبح هذه الدائرة نشطة للغاية وتجند أجزاء من الدوائر القشرية الحوفية المخططة، مثل العضلة المتكئة واللوزة والقشرة الجبهية الأمامية الوسطى والجزيرة بينما تظهر قلة النشاط أو منفصلة عن أجزاء أخرى من الدوائر المخططة، والتي تشمل هياكل مثل المخطط الترابطي والحركي. إن مشاركة الهياكل القشرية الحوفية ليست مفاجئة لأنها تشمل مناطق تؤثر على الدافع، وتم اقتراح أن أساس إدمان المخدرات يتضمن خللاً في المخطط البطني الظهري الإنسي، والذي يقع عند الإطلاق النهائي للمخدرات و/أو المحفزات المرتبطة بالمخدرات. (Basile et al.2021)، كما يوضحه الشكل (3) حيث يعرض الآليات العصبية التي تؤكد على التحول إلى التعاطي طويل الأمد.

ويشمل إدمان المخدرات، أو اضطراب تعاطي المواد، أنواعًا مختلفة من المواد، ولكل منها تأثيرات مميزة على الدماغ والجسم، وتشمل الفئات الرئيسية لإدمان المخدرات إدمان المنشطات (مثل الكوكايين والميثامفيتامين والأمفيتامينات؛ وإدمان المواد الأفيونية مثل الهيروين ومسكنات الألم الموصوفة طبيًا (مثل الأوكسيكودون والهيدروكودون والمورفين؛ وإدمان المهدئات (مثل البنزوديازيبينات والباربيتورات؛ وإدمان المهلوسات (الفطر السحري إل إس دي؛ وإدمان القنب (الماريجوانا والحشيش؛ وإدمان المستنشقات (المذيبات، الهباء الجوي، الغازات، النتريت) (على سبيل المثال، الغراء (الكلية)، مخففات الطلاء، البنزين، أكسيد النيتروز)؛ والإدمان الانفصالي مثل الكيتامين والديكستروميثورفان؛ بالإضافة إلى إدمان المخدرات الاصطناعية مثل القنب الاصطناعي، ويتضمن كل نوع من أنواع إدمان المخدرات مواد مختلفة ذات تأثيرات محددة، وإن فهم هذه الفروق أمر بالغ الأهمية لتطوير استراتيجيات علاجية فعالة تتناسب مع التحديات الفريدة التي تفرضها كل مادة.

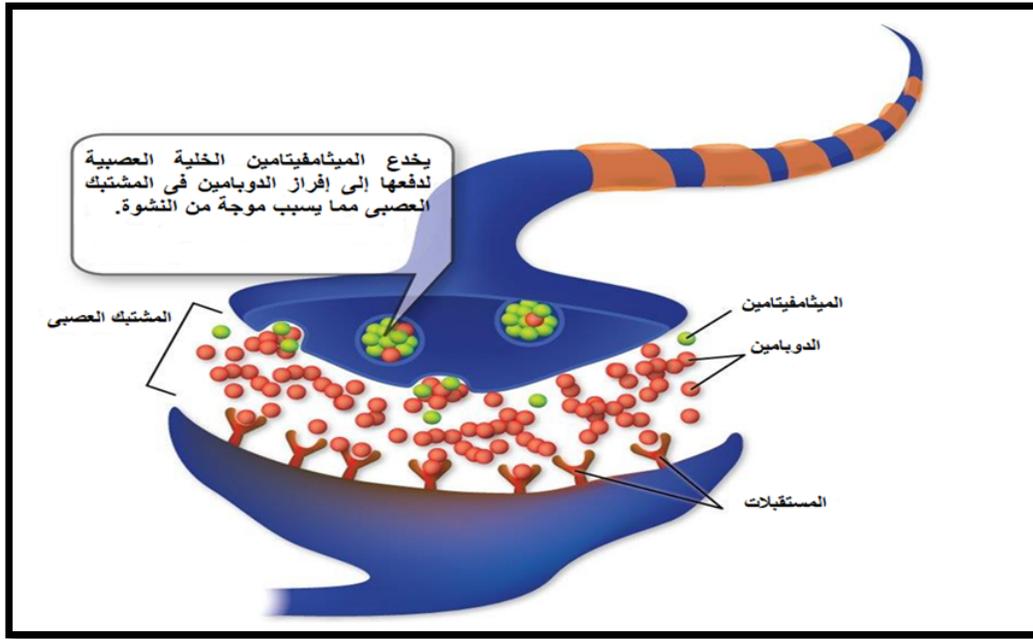
(Saif Al- Deen H Hassan, et. al. 2024.)



شكل (٣) الآليات العصبية التي تؤكد على التحول إلى التعاطي طويل الأمد

(Saif Al-Deen H. Hassan, et. al. 2024)

فمن بين التغييرات التي تقوم بها المخدرات والمنشطات التي يتعاطاها الأفراد وما تقوم به المواد النفسية المختلفة من تحايل على الخلايا والمشتبكات العصبية كما يلي يوضحه الشكل التالي:



شكل (٤) مثال على خداع الميثامفيتامينات للمشتبكات العصبية لدفعها لإفراز الدوبامين

لتحقيق النشوة. نقلاً عن (Saif Al-Deen H. Hassan, et. al. 2024)

ولبروز أهمية التعامل مع مشكلات التعاطي بأنواعه المختلفة، في ظل التسارع اللحظي في الاعتماد على الوسائل الحديثة وعلى رأسها استخدامات الذكاء الاصطناعي في دراسة تلك المشكلات، وهو الأمر الذي دعا العديد من الباحثين لتقديم مقترحات وأنظمة معتمدة على الذكاء الاصطناعي وأدواته المختلفة.

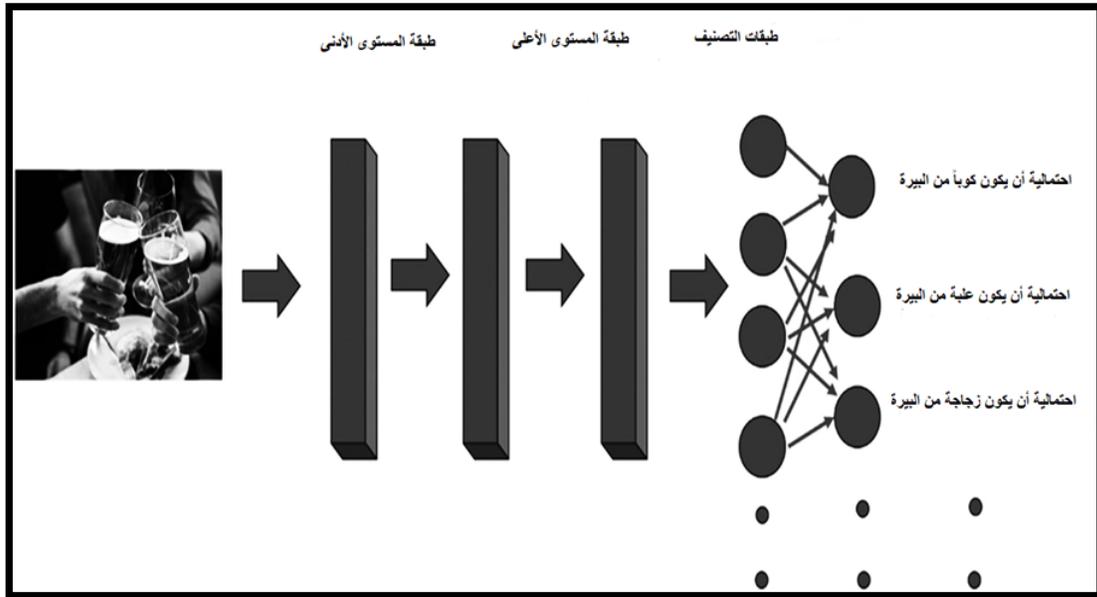
استعرض (Emmanuel Kuntsche, et. al. 2025)، الدراسات التي تستخدم التعلم الآلي في أبحاث تعاطي المخدرات، كما أخضعوها للدراسة، وضمنوها في الفصل المعنون الذكاء الاصطناعي في أبحاث تعاطي المخدرات، ضمن مرجع ساج عن الإدمان، ٢٠٢٥؛ حيث عرضوا وصفاً للذكاء الاصطناعي والتعلم الآلي والتعلم العميق، وبناءً على مراجعة تلك الأدبيات، عرضوا طرقاً مختلفة لكيفية استخدام التعلم الآلي في أبحاث تعاطي المخدرات والإدمان، ثم استخدموا تمثيلات الكحول في النصوص والصور الرقمية كمثال لكيفية استخدام تقنيات التعلم العميق المختلفة مع التركيز بشكل خاص على بيانات الوسائط، كما قدموا بعض الأفكار حول أحدث تطورات التعلم العميق وكيفية تطبيقه في أبحاث تعاطي المخدرات.

وقد فرقا بين التعلم العميق والذكاء الاصطناعي والتعلم الآلي كما يلي: التعلم الآلي: وهو مجال فرعي من الذكاء الاصطناعي (انظر الشكل ٢) حيث تُستخدم الخوارزميات والتقنيات الإحصائية لمنح أجهزة الكمبيوتر القدرة على التعلم من البيانات دون الحاجة إلى برمجتها صراحة، وقد أحدث التعلم الآلي ثورة في العديد من المجالات، على سبيل المثال، اكتشاف الخلايا السرطانية في الرعاية الصحية، واكتشاف المعاملات الاحتيالية في الخدمات المصرفية، والتنبؤ بأسعار المساكن، أو تحركات سوق الأوراق المالية في الاقتصاد.

ويتيح تطبيق تقنيات التعلم الآلي، مثل أسلوب نموذج بايز البسيط ونماذج الغابات العشوائية، وآلات المتجهات الداعمة وتخصيص ديريتشليت الكامن، وتحليل البيانات الأكثر تعقيداً على نطاق أوسع وبكفاءة أكبر من الطرق التقليدية.

لتقديم نظرة عامة حول كيفية تطبيق الذكاء الاصطناعي في أبحاث تعاطي المخدرات، أجروا بحثاً في الأدبيات في قواعد البيانات (PsycINFO) (OVID) و PubMed و S Googlecholar في يونيو ٢٠٢٣. تضمنت مصطلحات البحث مجموعة من الكلمات الرئيسية: الذكاء الاصطناعي، والتعلم الآلي، والتعلم العميق، وتعاطي المخدرات، والكحول، والشرب، والسكر، والتسمم، والنيكوتين، والتبغ، والسجائر الإلكترونية، والتدخين الإلكتروني، والهروين، والأفيون، والكوكايين، والإكستاسي، والميثامفيتامين، والقنب، والماريجوانا.

كانت النتيجة الأولى المدهشة هي أنه على الرغم من كونها منطقة جديدة وناشئة نسبياً حيث لم يتم نشر أي أبحاث إلا بعد عام ٢٠١٠؛ فقد تم نشر عدة مئات من الدراسات منذ ذلك الحين، معظمها في السنوات الخمس الماضية. ومن بينها، حدد الباحثون ١٦ مراجعة للأدبيات أو مقالة عامة، نُشرت هذه المقالات في السنوات الخمس الماضية (٢٠١٨-٢٠٢٣) ولخصت أدلة تطبيقات التعلم الآلي المختلفة ومجالات مختلفة من تعاطي المخدرات، ومن ثم؛ ركز الباحثون هنا بشكل استراتيجي على محتوى هذه المراجعات (أمثلة؛ Aggarwal et al؛ 2023، Beaulieu et al؛ 2021، Bouhadja & Bouramoul؛ 2022، Bickel et al؛ 2023، al Chhetri et؛ 2023، Ebrahimi et al؛ 2021، Fu et؛ 2023، al Garbin et؛ 2023)، وعبر تلك المراجعات كان إدمان المواد، وتعاطي الكحول أو المواد الأفيونية/ واضطراباتها، والنتائج المتعلقة بالتبغ (مثل الإقلاع عن التدخين) هي النتائج الأكثر دراسة. وكانت نماذج الغابات العشوائية، ونماذج آلة المتجهات الداعمة هي أكثر تقنيات التعلم الآلي استخدامًا، وقد تم نشر أكثر من ثلث المراجعات في العامين الماضيين وكانت أقدم المراجعات منذ خمس سنوات. تضمنت المراجعات ما بين ١١ و ٨٢ دراسة فردية (على الرغم من احتوائها أحيانًا على دراسات من دون تعلم آلي كانت غير ذات صلة). تلخص المراجعات المضمنة مجتمعة أدلة أكثر من ٣٥٠ دراسة فردية، وقد قدموا تفرقة بين المفاهيم المختلفة الشائعة في الربط بين الذكاء الاصطناعي وتعاطي المواد المخدرة نعرضها فيما يلي:



الشكل (٥) الاختلافات المفاهيمية بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق

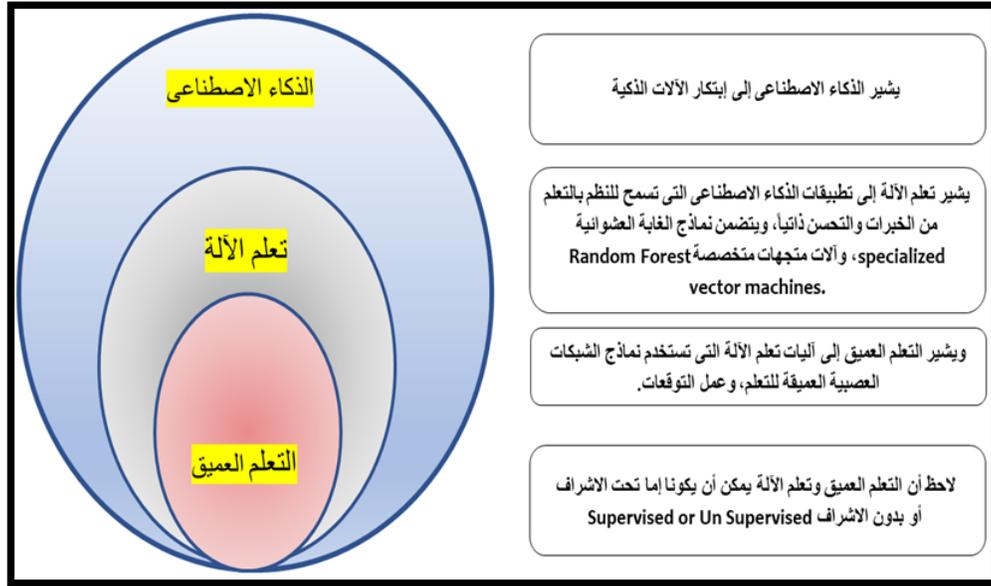
فغالبًا ما يتم تصنيف طرق التعلم الآلى على أنها "خاضعة للإشراف" أو "غير خاضعة للإشراف"؛ فى مهام التعلم الخاضع للإشراف، يتم تزويد الخوارزمية ببيانات تم شرحها يدويًا أو تتضمن تسميات. وفى تعاطى المخدرات، بناءً على المقالات التى حددها الباحثون فى مراجعة الأدبيات المقدمة للتحليل بالفصل المذكور؛ فإن التعلم الآلى الخاضع للإشراف أكثر شيوعًا من التعلم غير الخاضع للإشراف.

كانت أكثر طرق التعلم الآلى الخاضعة للإشراف شيوعًا والتى تم تحديدها فى تلك المراجعة للتراث هى نماذج الغابات العشوائية ونماذج آلة دعم المتجه حيث تُستخدم نماذج الغابات العشوائية لبناء نماذج التنبؤ من خلال إنشاء العديد من أشجار القرار بالبيانات المتاحة والتنبؤ إما بالتصنيف (عندما تكون النتيجة فئوية) أو القيمة العددية (عندما تكون النتيجة مستمرة). ولاختبار دقة هذه النماذج، تُستخدم البيانات المسماة لتحديد عدد المرات التى يتنبأ فيها النموذج بشكل صحيح بالنتيجة. وفى معظم الدراسات، استُخدمت نماذج الغابات العشوائية لبناء مصنف تنبؤى لاضطرابات تعاطى المواد (على سبيل المثال، للتنبؤ بدقة بالأفراد المعرضين لخطر كبير للإصابة باضطرابات تعاطى المواد؛ كما تقوم آلات المتجهات الداعمة برسم خريطة للبيانات على مساحة ميزة عالية الأبعاد وإنشاء مستو لفصل النقاط إلى فئات مختلفة (على سبيل المثال، تعاطى الكحول المنخفض والمتوسط والعالى). استُخدمت خوارزميات آلة المتجهات الداعمة لتحديد مستويات التسمم بالكحول من الكلام، واضطراب تعاطى الكحول، والتنبؤ بنتائج الإقلاع عن التدخين.

هذا وتُستخدم تقنية التعلم الآلى غير الخاضع للإشراف لتجميع البيانات على أساس التشابه - على سبيل المثال، لتحديد الأنماط فى أى نوع من البيانات غير المصنفة - وكانت أقل شيوعًا فى أبحاث تعاطى المواد حتى الآن (حسب بيانات الدراسة التى يقدمونها). على سبيل المثال، أثبت التعلم الآلى غير الخاضع للإشراف فائدته فى تحليل المناقشات والمحتوى المتعلق بالمواد على وسائل التواصل الاجتماعى من خلال التجميع (أى تجميع المحتوى المتشابه معًا)، مثل اكتشاف الموضوعات الشائعة وتلخيص المحتوى والمشاركات المتعلقة بإساءة استخدام الأدوية الموصوفة.

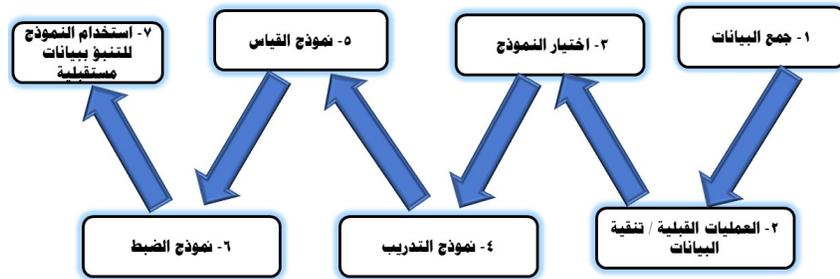
أما التعلم العميق: فهو مجال فرعى محدد من التعلم الآلى يستخدم الشبكات العصبية الاصطناعية التى تحاكي الدماغ البشرى، إذ تتكون هذه الشبكات من طبقات شبكة عصبية متعددة تبنى مستويات متزايدة باستمرار من الميزات المجردة (الشكل ٦)، على سبيل المثال، قد تكون طبقات الميزات منخفضة المستوى عبارة عن كاشفات للحواف فقط؛ وقد تكتشف طبقات الميزات عالية المستوى العجلات والرؤوس والأبواب وما إلى ذلك، أخيرًا؛ ستستخدم طبقات التصنيف فى نهاية الشبكة الميزات ذات المستوى الأعلى لإخراج احتمالية احتواء الصورة على قطة أو سيارة وما إلى ذلك. يأخذ نموذج

مثال في مجال الإدمان صورة تحتوي على مشروب كحولي كمدخل، سيتم بعد ذلك تمرير الصورة عبر الطبقات المتعددة للشبكة العصبية لإنتاج ميزات عالية المستوى أخيرًا مثل مقابض الأكواب وأعناق الزجاجات وما إلى ذلك، بعد ذلك، يمكن لطبقات التصنيف النهائية أن تأخذ هذه الميزات عالية المستوى للوصول إلى الاحتمال النهائي المتوقع لكوب البيرة أو زجاجة البيرة أو علبة البيرة وما إلى ذلك.



الشكل رقم (٦) يمثل بنية الشبكة العصبية العميقة

وبشأن التعلم العميق فكما يحدث في التعلم الآلي، يتم تصنيف مهام التعلم العميق إلى فئتين عريضتين، وهما التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف؛ في مهام التعلم الخاضع للإشراف، يتم تزويد خوارزمية التعلم العميق ببيانات تحتوي على تسميات مُعلقة يدويًا (الخطوة ٢ معالجة البيانات مسبقًا/تنقيتها في الشكل ٧) والهدف من الخوارزمية هو تحديث معالمها بطريقة تجعل التنبؤات قريبة من التسميات المُعلقة يدويًا الأصلية.



الشكل (٧) توضيح للخطوات السبع في عملية التعلم الآلي

وقدم الباحثون مثالاً للتعلم العميق الخاضع للإشراف في دراسات الحالة أدناه؛ حيث قاموا بشرح ٥١٨٧ سطرًا من كلمات الأغاني التي تحتوي على كلمات مرتبطة بالكحول أو لا تحتوي عليها، و٥٧١٨٦ صورة تحتوي على تمثيلات للمشروبات الكحولية أو لا تحتوي عليها. تم بعد ذلك إدخال مجموعات البيانات الموضحة عشوائيًا في البيانات لتدريب الخوارزميات (الخطوة ٤ في الشكل ٧) للتعرف على تمثيلات الكحول في كلمات الأغاني أو الصور (٧٠٪ من البيانات)، وضبط النموذج (١٠٪ من البيانات؛ الخطوة ٦ في الشكل ٧)، واختبار مدى دقة تنبؤ الخوارزميات في تحديد تمثيلات الكحول في كلمات الأغاني أو الصور (٢٠٪ من البيانات؛ الخطوة ٧ في الشكل ٧).

على النقيض من ذلك، في التعلم غير الخاضع للإشراف، لا تُستخدم أي تسميات مُعلّقة يدويًا لتعلم معلومات مفيدة. هناك فئتان فرعيتان عريضتان للتعلم غير الخاضع للإشراف، الأولى تركز على تجميع العناصر المتشابهة في مجموعات، والأخرى تسمى أحيانًا "التعلم الخاضع للإشراف الذاتي" حيث تُستخدم آليات بسيطة لإنشاء تسميات من البيانات (على سبيل المثال، التنبؤ بالكلمة التالية) دون أي تعليق يدوي. والهدف من التجميع هو العثور على مجموعات من العناصر التي لها خصائص متشابهة وبالتالي اكتشاف فئات عريضة مميزة من العناصر، على النقيض من ذلك، يُستخدم التعلم الخاضع للإشراف الذاتي لتدريب النماذج مسبقًا لتعلم ميزات/مفاهيم مفيدة عالية المستوى (على سبيل المثال، التنبؤ هو نوع من المشروبات الكحولية). يمكن بعد ذلك ضبط النماذج المدربة مسبقًا بدقة للمهام اللاحقة، ويتضمن الضبط الدقيق استخدام كمية صغيرة نسبيًا من البيانات المُعلّقة لإجراء تعديلات صغيرة على النموذج حتى يؤدي مهمة جديدة مثل تحديد ما إذا كانت كلمات الأغاني تذكر الكحول. (Emmanuel Kuntsche, et. al. 2025)

وقد أشار المؤلفون للعديد من النقاط التي خرجوا بها من دراسة التراث البحثي، منها:

**فوائد التعلم الآلي؛** حيث كانت إحدى نقاط القوة المشتركة التي تمت الإشارة إليها في الدراسات التي تمت مراجعتها هي قدرة التعلم الآلي على تحليل البيانات المعقدة على نطاق واسع وبسرعة ودقة نسبية. مثال، إمكانية التعامل مع أنواع مختلفة من مجموعات البيانات الكبيرة والمتنوعة وتلخيصها، بما في ذلك المسوحات الوطنية والاستبيانات، وبيانات التشخيص ونتائج العلاج، والوثائق السريرية، والبيانات التاريخية أو الشخصية، والسجلات الصحية، وبيانات وسائل التواصل الاجتماعي، مثل منشورات تويتر، ونظرًا لأن التعلم الآلي يمكنه معالجة كمية كبيرة من المعلومات بكفاءة (مثال، التاريخ الطبي الكامل للمريض)، فيمكن استخدامه للتنبؤات، وبالتالي تسهيل القرارات السريرية، كما لخص استخدام التعلم الآلي الخاضع للإشراف التنبؤ بنتائج الإقلاع عن التدخين عبر مجموعة من المتنبئين

(مثال، الاقتصادى، والديموغرافى الاجتماعى، وشدة، وتاريخ التدخين، وتأخير الخصم، وما إلى ذلك)، وهذا يسمح للأطباء بتخصيص التدخلات وتضمين محتوى أكثر تخصيصاً أو تحديداً.

وذكروا أيضاً الفجوات ومستقبل التعلم الآلى فى أبحاث الإدمان، فمع تزايد الشعبية وسهولة الوصول للباحثين، استناداً إلى الأدبيات التى تمت مراجعتها، يعتقدون أن هناك بعض التطبيقات المستقبلية الرئيسية لكيفية تنفيذ التعلم الآلى وكيفية استخدامه، وقد يكون أحد التطبيقات الرئيسية المستقبلية للتعلم العميق هو القدرة على مراقبة وتحليل البيانات بكفاءة أكبر؛ مثال، قد يكون التعلم العميق مفيداً بشكل خاص فى تحليل البيانات التى كان من الصعب على البشر التعليق عليها، مثل بيانات النصوص الكبيرة (مثل الكتب) أو الصور.

كما قدموا دراسة حالة: تمثل استخدام التعلم العميق لتحديد تمثيلات الكحول فى الوسائط الرقمية فهناك العديد من التطبيقات المتنوعة للتعلم الآلى، لكن أكثر التطبيقات إثارة للاهتمام هو تحليل بيانات الوسائط، على وجه التحديد، مساعدة التعلم الآلى واستخدامه مع بيانات الوسائط فى فهم: (١) كيفية تقديم تعاطى الكحول أو المواد الأخرى فى الوسائط، (٢) ما هو الدور والتأثير الذى يحدثه التعرض للكحول أو المواد فى الوسائط على سلوكيات تعاطى المواد، و(٣) ما هى فرص التدخل. وعرضوا كيفية استخدام التعلم العميق، فقد أثبتت الأبحاث أن التمرير عبر وسائل التواصل الاجتماعى (Instagram و Facebook وما إلى ذلك) يتعرض الناس لصور إيجابية للكحول من خلال التسويق (على سبيل المثال، المنشورات التى ترعاها صناعة الكحول) والصور التى ينشئها المستخدمون فى الأماكن المرخصة (الحانات والمطاعم والمهرجانات الموسيقية وما إلى ذلك) والشرب فى المنزل، وهذا أمر إشكالى لأن هناك صلة معروفة بين التعرض للكحول فى وسائل الإعلام وتعاطى الكحول (Curtis et al., 2018. ؛ Hanewinkel et al., 2014)، وقد يكون هذا الارتباط راجعاً إلى حقيقة مفادها أن التعرض لتمثيلات الكحول عبر الإنترنت قد يودى إلى زيادة (١) التعود على الشرب وتطبيعته، (٢) التوقعات المؤيدة للكحول والقبول الثقافى، و(٣) الجهل بالعواقب السلبية للإفراط فى الشرب.

ووضح للباحثين أن التعلم من الصفر هو أداة مثيرة للاهتمام لعلماء الاجتماع لأنه لا يتطلب تدريباً إضافياً أو بيانات مُعلقة، وخبرة أقل فى علوم الكمبيوتر، وموارد حسابية أقل. وقد يكون من المهم بشكل خاص المساعدة فى تحديد كمية التعرض للمحتوى المرتبط بالكحول فى الوسائط الرقمية، والذى تم قياسه بشكل أساسى باستخدام التقرير الذاتى (الذى يخضع لتحيز التذكر) أو تحليل المحتوى (الذى يستغرق وقتاً طويلاً ويكاد يكون من المستحيل إجراؤه على نطاق واسع. ( Emmanuel Kuntsche, et.al. ) (2025)

## الذكاء الاصطناعي والتنبؤ بإدمان بعض أشكال المواد النفسية وتأثيراتها

وللمزيد من شرح اهمية استخدام آليات الذكاء الصناعي فى التنبؤ بالتعاطى والإدمان؛ فقد تم طرح نهج جديد للتنبؤ بإدمان القنب من خلال دمج خوارزميات التعلم الآلى المدمجة (ML)، وتحديدًا خوارزمية التجميع K-means والانحدار الخطى (LR).

وتستخدم فى ذلك ما يسمى بالنمذجة التنبؤية؛ حيث إن مفتاح تصميم التفاعل نحو العادة الجيدة لصانع القرار المعنى (المتعلقة بقضية صحية) هو الجسر المرضى لهذه العادة الخاصة لصانع القرار من خلال ردود الفعل من النظام. وهذا يعنى أن تصميم التطبيق ينبغى أن يتم بمساعدة مجموعة قوية من المعرفة حول الأسس النفسية الفيزيولوجية والعصبية للعادة المخطط لها، وذلك من خلال، على سبيل المثال، التجارب النفسية الفيزيولوجية البشرية وإعادة النظر فى نماذج الإدمان فى علم الأعصاب.

يشير نموذج التفاعل التنبؤى إلى خوارزمية تنبؤية يتم تثبيتها فى صفحة ويب، والتي توفر تعزيزًا إيجابيًا من خلال نظام ترفيهى (يشبه لعبة بسيطة تعتمد على النقاط) لتعافى المريض من المشكلة الصحية المعنية، على سبيل المثال، إدمان الكحول. يمكن تثبيت مثل هذه اللعبة بسهولة على جهاز كمبيوتر أو كمبيوتر محمول أو هاتف ذكى أو جهاز لوحى أو سوار معصم، وذلك ببساطة عن طريق زيارة صفحة الويب ذات الصلة عبر الإنترنت. يمكن للمرضى ممارسة اللعبة فى وقت فراغهم، قبل موايدهم مع طبيبهم النفسى. يكافئهم التطبيق فى كل مرة يظهرون فيها سلوكًا، مثل شرب كمية معينة من منتج يحتوى على الكحول، وهو خيار حرموا أنفسهم من دعمه، من خلال منحهم نقاطًا تساعدهم فى الحصول على مرتبة فى لوحة المتصدرين فى اللعبة. إن الفوز بالرتبة هو بمثابة تعزيز للمكانة بالنسبة لهم. (Saif Al-Deen H. Hassan, et. al. 2024)

مثال ذلك ما أجراه كل من عبد الإله الهاشمى وزملائه بالمغرب ( Abdelilah Elhachimi, et. al. 2025) هدفت هذه الدراسة إلى اختبار قدرة خوارزمية تعلم آلى مركبة على التمييز بين المرضى المدمنين وغير المدمنين، باستخدام بيانات حقيقية جُمعت من مركز رعاية أولية للإدمان، تُركز البيانات المُجمعة بشكل أساسى على الحالة النفسية والإدراكية، وحالة إدمان المخدرات، والخلفية الاجتماعية والديموجرافية لكل مريض. كما تهدف هذه الدراسة إلى تطوير أداة فحص وتصنيف دقيقة، قائمة على التعلم الآلى، وموثوقة، واقتصادية؛ للتنبؤ بإدمان القنب باستخدام اختبارات سريرية موضوعية معتمدة وسهلة الاستخدام. صُممت هذه الأداة لتكون فى متناول حتى غير الممارسين، مما يُعالج تحديات نقص الكوادر، ويُساعد فى تطبيق التدابير الوقائية، وهذه الدراسة أجريت فى مراكش، المغرب، فى مركز تابع للجمعية الوطنية للحد من مخاطر المخدرات (DRR)، وشارك فيها ١٤٦ مشاركًا، من بين من سبق لهم

تعاطى القنب، ضمت إحدى المجموعات الفرعية متعاطين سلبين، بينما أظهرت مجموعة أخرى إدماناً عليه. استخدم البحث خصائص مستمدة من بيانات المرضى، مع التركيز على الحالة النفسية والمعرفية، وحالة الإدمان، والعوامل الاجتماعية والديموجرافية. كان الهدف هو تقييم فعالية خوارزميات التعلم الآلى المدمجة (K-means + LR) فى التمييز بين الأفراد المدمنين وغير المدمنين باستخدام بيانات واقعية من مركز رعاية أولية للإدمان. تشير النتائج إلى أن الطريقة المقترحة تقدم نتائج متوازنة؛ حيث تحقق دقة إجمالية تبلغ ٧٠٪، وحساسية ٦٥٪، وخصوصية ٨٦٪، وتُعد هذه النتائج جديرة بالملاحظة بشكل خاص عند مقارنتها بدراسات التعلم الآلى الأخرى فى أبحاث الإدمان. تُظهر الخوارزمية المُدمجة إمكانيات واعدة بدقة تنافسية وخصوصية عالية. وسيكون بذل المزيد من الجهود لتحسين حساسية النموذج والتحقق من صحته فى بيانات متنوعة أمرًا ضروريًا لتطوير النمذجة التنبؤية فى هذا المجال، تُسهم النتائج فى الأبحاث الحالية - من خلال تطوير أدوات بسيطة وفعالة - الكشف المبكر عن إدمان القنب مما قد يُسهم فى وضع استراتيجيات وقائية وعلاجية للحد من انتشاره. أدوات بسيطة وفعالة للكشف المبكر عن إدمان القنب، مما قد يُسهم فى وضع استراتيجيات وقائية وعلاجية للحد من انتشاره. وتنقسم طرق فحص تعاطى القنب بشكل رئيسى إلى اختبارات بيولوجية وتقييمات سريرية. فمن ناحية؛ تكشف الطرق البيولوجية عن القنب فى سوائل الجسم مثل البول والدم واللعاب والشعر. ومع ذلك؛ فإن لهذه الاختبارات قيودًا، بما فى ذلك تحديد جزيئات مرجعية معينة، مما قد يسمح بعدم اكتشاف بعض المركبات المرتبطة بالقنب. علاوة على ذلك؛ فإن الاختبار البيولوجى الإيجابى يؤكد فقط تعاطى القنب، وليس الإدمان. من ناحية أخرى؛ تؤكد التقييمات السريرية على الإدمان من خلال فحص أنماط الاستهلاك والحالات النفسية. ومع ذلك؛ قد تُدخل هذه الاستبيانات تحيزات مثل نقص الإبلاغ بسبب الخجل أو الإنكار. علاوة على ذلك، تقتصر غالبية هذه الاستبيانات إلى التوافق مع المعايير الموضحة فى الطبعة الخامسة من الدليل التشخيصى والإحصائى للاضطرابات العقلية (DSM-5) وبالتالي؛ ينبغى إجراء التشخيصات السريرية القائمة على هذه الأدوات تحت إشراف إحصائى إدمان لضمان دقة وموثوقية عملية الفحص.

وفى الآونة الأخيرة، كان لدمج تقنيات التعلم الآلى (ML) والذكاء الاصطناعى (AI) فى الرعاية الصحية تأثير إيجابى على جميع جوانب الرعاية الصحية تقريبًا، من اكتشاف المرض إلى التنبؤ بتطوره والوقاية منه. ومع ذلك؛ على الرغم من فوائده، فإن استخدام التعلم الآلى فى أبحاث الإدمان لا يزال محدودًا. إلى جانب ذلك؛ فإن أحد أكثر تطبيقات التعلم الآلى شيوعًا هو إجراء التنبؤات Prediction،

مثل استخدامه للتمييز بين الخصائص الفردية (مثل أولئك الذين يعانون من سلوك الإفراط في الشرب ومن لا يعانون منه) أو للتنبؤ بالأحداث (مثل جرعة زائدة من المواد الأفيونية).

وفي هذا الشأن يشيع تصنيف مناهج التعلم الآلى إلى مجموعتين رئيسيتين: التعلم الخاضع للإشراف والتعلم غير الخاضع للإشراف، يتيح استخدام التعلم المُشرف لمشاكل الإدمان تحديد الفئة المُعرّضة للخطر، واستخلاص أهم المتغيرات المرتبطة باضطرابات تعاطى المواد (SUD)، والتمييز بين الفئة المُصابة وغير المُصابة باضطرابات تعاطى المواد، بينما تُساعد أساليب التعلم غير المُشرف على اكتشاف العلاقات والتجمعات الناشئة داخل البيانات دون أى هدف مُحدد مُسبقاً. يبرز التجميع باستخدام متوسطات K كخوارزمية سائدة فى التعلم الآلى غير المُشرف، ويُستخدم بشكل متكرر، على سبيل المثال، لتصنيف الأفراد الذين يعانون من اضطرابات تعاطى المواد بناءً على خصائص نفسية واجتماعية أو سريرية مُماثلة فى مشاكل التصنيف، وتُنظّم الاستجابة عادةً فى فئات (مثل حدوث جرعة زائدة من المواد الأفيونية).

جانب آخر من جوانب التعلم الآلى هو التعلم العميق، الذى تُمكن تطبيقاته فى علم الإدمان من تصنيف دقيق للغاية فى الكشف عن المؤشرات الرئيسية للأفراد المُدمنين على المواد الأفيونية، وخصوصاً أولئك الذين يستخدمونها على المدى الطويل؛ حيث يمتلك التعلم الآلى القدرة على مُعالجة مجموعة مُتنوعة من التحديات فى علم الإدمان، فهو يُستخدم كإطار عمل من التعلم الآلى للتنبؤ بفعالية علاج اضطرابات تعاطى المواد النفسية، بالإضافة إلى ذلك، يُعدّ استخدام التعلم الآلى وبيانات التصوير بالرنين المغناطيسى الوظيفى مؤشراً حيوياً محتملاً لتحديد إدمان الكوكايين. علاوة على ذلك؛ يُمكن أن يُساعد استخدام التعلم الآلى فى تحديد الشباب والبالغين المعرضين للخطر بدقة والذين يحتاجون إلى الوقاية من اضطرابات تعاطى المواد، وأخيراً؛ يُمكن أن يُساعد التعلم الآلى فى اكتشاف الأسس الجينية للإدمان؛ حيث قدمت دراسات حديثة طريقة لفحص إدمان القنب (الحشيش) من خلال الجمع بين التعلم الآلى واختبارات التقييم النفسى والمعرفى، مما يُسلط الضوء على نجاح نموذج آلة ناقل الدعم (SVM) فى تحديد إدمان القنب. (Abdelilah Elhachimi, et. al. 2025)

ونظراً لأن إساءة استخدام المخدرات مجموعة غير متجانسة ومعقدة من الحالات السلوكية المنتشرة بشكل كبير فى إعدادات المستشفى وتحدث بشكل متكرر؛ فإنه يوجد عدد قليل من الحلول على مستوى المستشفيات لتحديد هذه الحالات بشكل شامل وموثوق لتحديد أولويات الرعاية وتوجيه العلاج؛ فقد هدفت دراسة ماجد أفشار وزملائه (Majid Afshar, et all.2022) إلى تطبيق معالجة اللغة الطبيعية (NLP) فى شكل بناء أداة آلية للبرمجة اللغوية العصبية لفحص إساءة استخدام المواد النفسية باستخدام

البيانات التي تم جمعها في ملاحظات السجلات الصحية الإلكترونية أثناء الرعاية المعتادة وإظهار قدراتها على الفحص؛ حيث قاموا بفحص تطوير مصنف واحد للكشف عن أنواع متعددة من إساءة استخدام المواد بسهولة التنفيذ، وتدريبه على التعلم المشترك عبر المصنفات (استخدام المواد المتعددة)، والكفاءة في امتلاك نموذج واحد، وبشكل أكثر تحديداً بهدف التطوير والتحقق من صحة مصنف التعلم الآلى الذى يمكنه تحديد إساءة استخدام الكحول وإساءة استخدام المواد الأفيونية وإساءة استخدام المخدرات غير الأفيونية باستخدام ملاحظات السجلات الصحية الإلكترونية التي تم جمعها خلال اليوم الأول من دخول المستشفى. ويمكن دمج التوصيات الحالية للكشف عن أنواع متعددة من إساءة استخدام تلك المواد فى نموذج واحد للتعلم الآلى لتقليل التكرار فى دعم القرار السريرى (الكلينيكى) لمقدم الخدمة، وربما تقليل الضغوط التي يمثلها الإنذار.

وتم تطبيق النموذج على الملاحظات السريرية التي تم جمعها فى السجل الصحى الإلكتروني (EHR) للفحص الدقيق لإساءة استخدام المخدرات. استخدموا فيها عدداً من الأساليب حيث تم تدريب النموذج وتطويره على مجموعة بيانات مرجعية مشتقة من برنامج على مستوى المستشفى فى المركز الطبى بجامعة راش (RUMC)، بشيكاغو، إلينوى، الولايات المتحدة الأمريكية، والتي تضم استخدام مقابلات تشخيصية منظمة لفحص المرضى المقبولين يدوياً على مدار ٢٧ شهراً (بين ١ أكتوبر ٢٠١٧ و ٣١ ديسمبر ٢٠١٩؛ وبلغ عددهم ٥٤ ٩١٥)، كان اختبار تحديد اضطراب تعاطى الكحول، وأداة فحص تعاطى المخدرات بمثابة معايير مرجعية. تم تعيين أول ٢٤ ساعة من الملاحظات فى السجلات الصحية الإلكترونية إلى المفردات الطبية الموحدة وإدخالها فى تسمية واحدة ومتعددة التسميات مع نماذج الشبكة العصبية ذات المهام المساعدة. تم التحقق الزمنى من النموذج باستخدام بيانات من الأشهر الأثنى عشر اللاحقة على مجموعة فرعية من مرضى "جامعة راش" RUMC (بلغ عددهم ١٦٩١٧). وتم إجراء التحقق الخارجى باستخدام بيانات من المركز الطبى بجامعة لويولا، شيكاغو، إلينوى، بالولايات المتحدة الأمريكية بين ١ يناير ٢٠٠٧ و ٣٠ سبتمبر ٢٠١٧ (على عدد ١٩٩١ مريضاً بالغاً).

وكانت النتيجة الأولية هى التمييز بين المجموعات بسبب إساءة استخدام الكحول أو إساءة استخدام المواد الأفيونية أو إساءة استخدام المخدرات غير الأفيونية. تم تقييم التمييز حسب المنطقة الواقعة تحت منحنى الخصائص التشغيلية للمستقبل (AUROC)، وتم قياس ميل المعايير والاعتراض باستخدام مؤشر عدم الموثوقية. أجريت تقييمات التحيز عبر المجموعات الديموجرافية الفرعية وغيرها. وتم تدريب النموذج على مجموعة أساءت استخدام المخدرات بنسبة ٥,٣% (عددها ١٩٢١) مع أى نوع من المواد، كان لدى ٢٢٠ (١١%) من ١٩٢١ مريضاً يعانون من إساءة استخدام المخدرات أكثر

من نوع واحد من سوء الاستخدام. وكان متوسط AUROC لمصنف الشبكة العصبية التلافيفية متعددة التسميات ٠,٩٧ (٩٥٪) (CI 0.96-0.98) أثناء التحقق الزمني لجميع أنواع الإساءة في استخدام المواد. وتمت معايرة النموذج جيدا وأظهر صحة وجه جيدة مع ميزات النموذج التي تحتوى على إشارات صريحة لسلوك التعاطى الشاذ للمخدرات. كما حدث معدل سلبي كاذب من (٠ إلى ١٨ إلى ٠ إلى ١٩) ومعدل إيجابى كاذب قدره ٠٣٠٠ بين المجموعات الديموجرافية من السود غير الإسبانية، والبيض غير اللاتينيين. أما فى التحقق الخارجى؛ فقد كانت الخصائص التشغيلية لـ AUROCs لإساءة استخدام الكحول والمواد الأفيونية ٠,٨٨ (بدرجة ثقة ٩٥٪ ٠,٨٦-٠,٩٠) و ٠,٩٤ (٠,٩٢-٠,٩٥) ذ، على التوالي، وفسر الباحثون تلك النتائج أنهم بتطويرهم نهجا جديدا ودقيقا للاستفادة من أول ٢٤ ساعة من ملاحظات السجلات الصحية الإلكترونية لفحص أنواع متعددة من إساءة استخدام المخدرات.

هذا وقد أظهر النموذج المقدم معايرة جيدة وصدقًا ظاهريًا، مع وجود تفاوتات قليلة عبر المجموعات الفرعية للمرضى أثناء التحقق الزمني فى عام جائحة COVID-19 (يناير - ٣١ ديسمبر ٢٠٢٠).

ومع هذا النموذج؛ قدم الباحثون نهجا آليا لفحص أنواع متعددة من إساءة استخدام المواد فى وقت واحد، إذ يمكن أن يتغير أداء التنبؤ بمرور الوقت أو فى بيئات مختلفة للمرضى؛ حيث يختلف انتشار إساءة استخدام المخدرات. كما أظهرت التغيرات فى الانتشار بمرور الوقت (من ٧٠٪ إلى ٥٤٪) أثناء جائحة COVID-19 مما تطلب إعادة معايرة المصنف بحيث لا يتم التقليل من المخاطر المتوقعة عبر الأفراد، وتعد المعايرة Calibration سببا رئيسيا لفشل النماذج فى الأداء الجيد فى البيئات الخارجية والتقاط المخاطر المناسبة بين المجموعات، فإعادة التطوير المستمر لنموذج جديد غير ممكن لأنه يستغرق وقتا طويلا ويتطلب بيانات وفيرة ويهدر معلومات مفيدة محتملة من النماذج الحالية، وبالتالي؛ فإن تحديث النموذج أو إعادة معايرته هو بديل فعال وموصى به من قبل إرشادات TRIPOD.21، وكان لمصنف التعلم الآلى المحدث معدل ورقم إنذار مقبولين مطلوب لتقييم التنبهات.

تدعم هذه الخصائص الفحص الآلى الذى يمكن أن يتغلب على تحديات التوظيف ويحسن معدلات الفحص فى المستشفيات إساءة استخدام المواد هى حالة معقدة تحدث بشكل متكرر كإساءة استخدام متعددة المواد. كما يوفر النموذج ميزة نمذجة أنواع مختلفة من تعاطى المواد بشكل مشترك بدلا من استخدام النماذج الفردية؛ إذ تتمتع طرق التعلم الآلى بميزة على الأساليب الإحصائية والنصية التقليدية؛ لإمكانية فحصها لتعقيدات جميع التفاعلات ومجموعات المصطلحات، كما يتضح من نموذج الشبكة العصبية التلافيفية، الذى يحتوى على أكثر من ١٢ مليون كلمة من مفردات تضم أكثر من

٣٥٠٠٠ مصطلح فريد. تفوق المصنف متعدد التسميات الذى قدمه الباحثون على مصنفات الكحول الأفيونية أحادية التسمية، والكحول أحادية التسمية، مع حساسية عالية، بما فى ذلك ٨٧٪ لإساءة استخدام المواد الأفيونية؛ حيث يتعامل نهج التعلم الآلى مع كل كلمة مميزة ولا يتطلب خبرة فى الموضوع، على عكس النماذج التى اعتمدت على الكلمات الرئيسية والأنظمة القائمة على القواعد. وقد تم تدريب الأنظمة الأخرى القائمة على الذكاء الاصطناعى على البيانات التى لم تكن متاحة بسهولة فى السجلات الصحية الإلكترونية، مع التركيز على مجموعة فرعية من المرضى الذين يعانون من اضطرابات استخدام المواد الأفيونية، أو كانت تقتصر على البيانات المنظمة؛ حيث تم إدراج ملاحظات السجلات الصحية الإلكترونية وقابليتها للتفسير كميزات فى نماذج التعلم العميق التى قدمها الباحثون مع مناهج فى الذكاء الاصطناعى القابل للتطبيق، وأظهر أن ميزات تحديد إساءة استخدام المواد كانت مصطلحات ذات صلة وأن الاكتشاف لم يقتصر على مجرد شروط صريحة لتعاطى المخدرات.

كان للمصنف مقاييس أداء أقل لمجموعة إساءة استخدام المخدرات غير الأفيونية، وربما يرجع ذلك إلى صغر حجم العينة وعدم التجانس فى أنواع تعاطى المخدرات، ومع ذلك؛ يوفر المصنف المقدم المرونة لإيقاف تشغيل أى ملصق واحد، وقد تكون هذه المرونة ضرورية للمجموعة غير الأفيونية؛ حيث تظل خيارات العلاج نادرة، إذ إن علاجات الكوكايين أو الميثامفيتامين أو البنزوديازيبينات أقل رسوخاً من تعاطى الكحول أو المواد الأفيونية ولكنها تظل مهمة للرصد حالياً، ويعد الفحص الحالى على مستوى المستشفى فى RUMC جزءاً من فحص أكبر وتدخل قصير وإحالة إلى برنامج العلاج. (Majid Afshar,2024)

كما قدم كل من (Jose, Jwala, and B. Suresh Kumar,2024) نهجاً جديداً يستفيد من تقنيات الذكاء الاصطناعى والتعلم الآلى (ML) للتنبؤ بإدمان المخدرات بين الطلاب. تتضمن المنهجية المقترحة جمع بيانات شاملة تشمل عوامل مختلفة مثل التركيبة السكانية والحالة الاجتماعية والاقتصادية والأداء الأكاديمى والتاريخ العائلى للإدمان وتأثير الأقران وحالة الصحة العقلية وتاريخ تعاطى المخدرات. وبعد المعالجة المسبقة للبيانات واختيار الميزات؛ تم تدريب وتقييم خوارزميات التعلم الآلى المختلفة بما فى ذلك الانحدار اللوجستى LR. وأشجار القرار DT. والغابات العشوائية RF. وآلات ناقلات الدعم (SVM) والشبكات العصبية لتحديد النموذج الأكثر فعالية للتنبؤ. وتم نشر النموذج المطور فى واجهة سهلة الاستخدام، مما يتيح جهود التدخل والوقاية المبكرة للتخفيف من المخاطر المرتبطة بتعاطى المخدرات بين الطلاب. كما يتم تناول الاعتبارات الأخلاقية المتعلقة بخصوصية البيانات والإنصاف والشفافية فى

جميع أنحاء الدراسة. وتوضح النتائج التجريبية فعالية النهج المقترح فى التنبؤ بإدمان المخدرات لدى الطلاب، وبالتالي المساهمة فى التدخلات الاستباقية لتعزيز رفاهية الطلاب وصحتهم.

وبنى الباحثان عملهما على أن انتشار إدمان المخدرات بين الطلاب أصبح مصدر قلق ملح فى المجتمع المعاصر؛ حيث لا يؤثر تعاطى المخدرات على الأداء الأكاديمى فحسب؛ بل يشكل أيضا مخاطر كبيرة على الصحة البدنية والعقلية، الأمر الذى يعتبر معه التحديد والتدخل المبكر أمراً بالغ الأهمية للتخفيف من هذه المخاطر وتقديم الدعم المناسب للأفراد المتضررين، وتم استخدام نهج مبتكر يستخدم تقنيات الذكاء الاصطناعى والتعلم الآلى (ML) للتنبؤ بإدمان المخدرات بين الطلاب؛ حيث استكشفت الدراسات السابقة عوامل مختلفة تساهم فى إدمان المخدرات بين الطلاب، بما فى ذلك الحالة الاجتماعية والاقتصادية، والتاريخ العائلى، وتأثير الأقران، وحالة الصحة العقلية. وتم اقتراح العديد من أساليب النمذجة التنبؤية، بدءاً من الأساليب الإحصائية التقليدية إلى خوارزميات التعلم الآلى المتقدمة. ومع ذلك؛ غالباً ما تفتقر تلك المنهجيات إلى الاختيار الشامل للميزات وتفشل فى الاستفادة من الإمكانيات الكاملة لتقنيات الذكاء الاصطناعى والتعلم الآلى.

وضمن الباحثان التنبؤ بإدمان المخدرات لدى طلاب الجامعات باستخدام الخوارزميات التنبؤية وفق عدة خطوات؛ وبمنظرة عامة على عملية التنبؤ بإدمان المخدرات؛ حيث تتكون مجموعة البيانات المستخدمة فى هذه الدراسة من معلومات شاملة تم جمعها من مجموعة متنوعة من طلاب الجامعات عبر مؤسسات متعددة. تم جمع البيانات من (حجم العينة، على سبيل المثال، ٥,٠٠٠ طالب)، يمثلون خلفيات ديموجرافية مختلفة، والتخصصات الأكاديمية، والأوضاع الاجتماعية والاقتصادية. تم جمع مجموعة البيانات المتنوعة هذه من المؤسسات الموجودة فى كل من المناطق الحضرية والريفية، مما يضمن أن النموذج يمثل مجموعة واسعة من العوامل البيئية والاجتماعية التى تؤثر على سلوك الطلاب. كما تضمنت مصادر البيانات الاستطلاعات والسجلات المؤسسية والمقابلات، كما تم اختيار متغيرات مثل العمر والجنس والأداء الأكاديمى والتاريخ العائلى للإدمان وتأثيرات الأقران وحالة الصحة العقلية وأنماط تعاطى المخدرات. وتم تجميع المعلومات الأساسية من طلاب الجامعات حول ملفهم السكانى، ووضعهم الأكاديمى، والخلفية الاجتماعية والاقتصادية، والتاريخ العائلى للسلوك الإدمانى، وضغط الأقران، والصحة العقلية، وتعاطى المخدرات فى الماضى. كما تم التحقق من حصول الدراسة على الموافقة الأخلاقية من مجلس المراجعة المؤسسية المناسب (IRB) أو لجنة الأخلاقيات قبل البدء فى أى جمع للبيانات. طوال عملية جمع البيانات، من الضرورى احترام خصوصية وسرية المشاركين واتباع المعايير الأخلاقية (Pelz). جمع البيانات حول الأداء الأكاديمى، بما فى ذلك المعدل التراكمى والحضور

في الفصل والتخصص والإنجازات الأكاديمية، كما تم وضع الضغوط الأكاديمية والأداء ضمن العوامل المهمة التي تساهم في سلوكيات تعاطي المخدرات بين طلاب الجامعات. كما تم تضمين أسئلة حول التاريخ العائلي للإدمان، مثل ما إذا كان لدى أى من أفراد الأسرة تاريخ من تعاطي المخدرات أو الإدمان. كما تلعب الوراثة والتأثيرات العائلية دورًا مهمًا في تهيئة الأفراد لاضطرابات تعاطي المخدرات. قام الباحثان بتقييم تأثير الأقران من خلال السؤال عن الشبكات الاجتماعية والصدقات والتفاعلات مع أقرانهم الذين يتعاطون المخدرات. وتضمن أسئلة المتعلقة بحالة الصحة العقلية، مثل أعراض الاكتئاب أو القلق أو التوتر أو الاضطرابات النفسية الأخرى.

تم استخدام قواعد البيانات أو مجموعات البيانات الحالية التي تحتوي على معلومات ذات صلة بالتركيبة السكانية لطلاب الجامعات والأداء الأكاديمي وسلوكيات تعاطي المخدرات وحالة الصحة العقلية. التأكد من أن مصادر البيانات ذات السمعة الطيبة التي تتوافق مع لوائح حماية البيانات من أجل ضمان الاتساق في جميع أنحاء مجموعات البيانات.

وللتأكد من عمل الميزات المختارة على تحسين أداء النموذج المقدم والتعميم جيدًا على البيانات الجديدة، قام الباحثان بالتحقق من صحتها أثناء عملية التحقق من الصدق؛ حيث تتبع التغييرات في أداء النموذج (الدقة، درجة F1، إلخ) باستخدام مجموعات فرعية مختلفة من الميزات لتحديد أفضل مجموعة ميزات للتنبؤ بإدمان المخدرات. اختيار النموذج تم تجريب خوارزميات تنبؤية مختلفة، مثل الشبكات العصبية NN، والانحدار اللوجستي LR، وآلات ناقلات الدعم (SVM)، وأشجار القرار DT، والغابات العشوائية RT، وما إلى ذلك. باستخدام البيانات المعالجة مسبقًا؛ قاما بتدريب وتقييم هذه النماذج للعثور على أفضل خوارزمية للتنبؤ بإدمان المخدرات. وقد وصفا أشجار القرار بأنها: استنادًا إلى قيم الميزة، تقسم أشجار القرار مساحة المعالم إلى مناطق منفصلة. وقاما بتدريب النموذج باستخدام البيانات التي تمت معالجتها مسبقًا، كما قاما بتدريب نموذج شجرة القرار. وكان التقييم عبر استخدام نفس مقاييس التقييم مثل الانحدار اللوجستي لتقييم أداء النموذج ("شجرة القرار"). ووصفا الغابات العشوائية بأنها تقنيات تعلم جماعية تعزز الأداء التنبؤي من خلال دمج العديد من أشجار القرار.

فيما يلي ملخص لأداء النماذج: قدمت الشبكات العصبية والغابات العشوائية أعلى دقة وقيم AUC ROC، مما يشير إلى أدائها المتفوق في التنبؤ بإدمان المخدرات بين طلاب الجامعات. حققت الشبكات العصبية دقة بنسبة ٩٠٪، مع AUC-ROC تبلغ ٠.٩١، بينما حققت Random Forests دقة ٨٨٪ و AUC-ROC تبلغ ٠.٩٠. كان أداء الانحدار اللوجستي وأشجار القرار و SVM جيدًا أيضًا ولكنه كان أقل فعالية من طرق المجموعة.

تم تضمين التصورات التالية: مصفوفات الارتباك: تبرز مصفوفات الارتباك لكل نموذج عدد الإيجابيات الحقيقية والسلبيات الحقيقية والإيجابيات الخاطئة والسلبيات الخاطئة. توفر هذه المصفوفات نظرة ثاقبة لدقة التنبؤ بالنموذج وتوزيع الأخطاء عبر الفئات. منحنيات ROC: تصور منحنيات خاصة بتشغيل جهاز الاستقبال (ROC) المفاضلة بين الحساسية (الاستدعاء) والخصوصية عبر قيم العتبة المختلفة. تظهر منحنيات نماذج الشبكات العصبية والغابة العشوائية نهجا أقرب إلى الزاوية العلوية اليسرى من الرسم البياني، مما يدل على أدائها العالي.

وأظهرت نتائج التجارب مدى نجاح الطريقة المستخدمة في التنبؤ بإدمان الطلاب على المخدرات. ويحقق النموذج المنشور دقة عالية ويظهر أداء قويا عبر مجموعات البيانات المتنوعة.

في الختام نفذت هذه الدراسة بنجاح خوارزميات التعلم الآلي المختلفة للتنبؤ بإدمان المخدرات بين طلاب الجامعات، مما يسلط الضوء على أهمية الأساليب القائمة على البيانات في مواجهة تحديات الصحة العامة. أظهرت النتائج أن نماذج مثل الشبكات العصبية والغابات العشوائية قدمت دقة فائقة وقيم AUC-ROC، مما يشير إلى فعاليتها في تحديد الأفراد المعرضين للخطر. من خلال المعالجة المسبقة الصارمة للبيانات واختيار الميزات، أكدنا من استخدام المعلومات الأكثر صلة فقط، مما عزز أداء النموذج وقابليته للتفسير. كما قدم استخدام مقاييس التقييم مثل الدقة والدقة والاستدعاء ودرجة F1 تقييما شاملا للقرارات التنبؤية لكل نموذج، مما يعزز موثوقية النتائج التي توصلنا إليها. من خلال استخدام هذا الإطار التنبؤي، ويمكن للمؤسسات التعليمية تنفيذ استراتيجيات التدخل المبكر، مما يساعد في النهاية في الوقاية من تعاطي المخدرات بين الطلاب. كما يؤكد دمج تقنيات التعلم الآلي في تطبيقات العالم الحقيقي على قدرتها على المساهمة بشكل كبير في صحة الطلاب ورفاههم، وبشكل عام؛ يضع هذا البحث الأساس لمزيد من الاستكشاف في تقنيات النمذجة التنبؤية المتقدمة، مما يشجع الجهود المستمرة لتعزيز دقة وقابلية تطبيق طرق التنبؤ بإدمان المخدرات في سياقات تعليمية متنوعة. (Jose, Jwala, and B. Suresh Kumar,2024)

من ناحية أخرى كان الحد من الانتكاس Relapse من بين الاهتمامات التي أدخل فيها الذكاء الاصطناعي؛ حيث درس كل من (Chrisweena Jerusha E & Saranya T.S.2024) اضطراب تعاطي القنب (الحشيش) CUD وهو حالة منتشرة وصعبة تتميز بمعدلات عالية من الانتكاس على الرغم من جهود التدخل التقليدية. والوقاية الفعالة من الانتكاس أمر حيوي لدعم التعافي المستدام. ومع ذلك؛ فإن الأساليب الحالية - التي تعتمد بشكل أساسي على البيانات المبلغ عنها ذاتيا والتقييمات السريرية الدورية - محدودة بسبب التحيزات وغياب المراقبة في الوقت الفعلي. وقد بحث الباحثان إمكانات الذكاء

الاصطناعي (AI) في تحويل الوقاية من الانتكاس من ذلك الاضطراب (CUD) من خلال المراقبة المستمرة للإشارات السلوكية المرتبطة بزيادة خطر الانتكاس من خلال الاستفادة من التطورات الحديثة في التعلم الآلي والصحة السلوكية، وتدرس هذه الدراسة تطبيقات الذكاء الاصطناعي لتتبع المؤشرات الرئيسية مثل الحالة المزاجية والمشاركة الاجتماعية والنشاط البدني وأنماط النوم. من خلال استخدام البيانات من المصادر الرقمية مثل الهواتف الذكية والأجهزة القابلة للارتداء، إذ يمكن للأنظمة التي تعتمد على الذكاء الاصطناعي تحديد التغييرات السلوكية الدقيقة التي قد تسبق الانتكاس، مما يوفر رؤى في الوقت المناسب للأفراد في مرحلة التعافي وشبكات الدعم الخاصة بهم، بالإضافة إلى ذلك، تتناول الدراسة المخاوف الأخلاقية والخصوصية، وتسلط الضوء على أهمية المعالجة الآمنة للبيانات، وموافقة المستخدم، وتطوير نماذج الذكاء الاصطناعي العادلة.

وتؤكد الدراسة على وعد الذكاء الاصطناعي في تحسين استراتيجيات الوقاية من الانتكاس ويحدد الاتجاهات المستقبلية لإنشاء أدوات الذكاء الاصطناعي الأكثر دقة وتكيفاً المصممة خصيصاً لتلبية احتياجات الأفراد الذين يتعافون من اضطراب تعاطي القنب (الحشيش) CUD .

ونظراً لشيوع استخدام القنب بشكل متزايد بسبب تغير المواقف القانونية والاجتماعية؛ فقد لفت هذا الارتفاع في الاستخدام الانتباه أيضاً إلى اضطراب استخدام القنب (CUD)، والذي يؤثر على نحو ٣٠٪ من مستخدمي القنب، فغالبا ما يجد الأفراد الذين يعانون من CUD صعوبة في البقاء متيقظين على المدى الطويل بسبب معدلات الانتكاس المرتفعة، يمكن أن يحدث الانتكاس بسبب عوامل مختلفة، بما في ذلك الإشارات البيئية والتوتر والمحفزات النفسية، مما يجعل التعافي صعباً.

يؤكد هذا الوضع الحاجة الملحة لأنظمة مراقبة فعالة لمساعدة الناس على الحفاظ على الرصانة على المدى الطويل وتقليل التكاليف الاجتماعية وتكاليف الرعاية الصحية المرتبطة بـCUD، وتشير الدراسة إلى استهداف برامج الوقاية الحالية من الانتكاس مراقبة المخاطر، لكن معدلات الانتكاس المرتفعة تشير إلى أن هذه الأساليب لها قيود وتحتاج إلى استراتيجيات دعم أكثر فعالية، فالتحديات في الأساليب الحالية غالباً ما تعتمد طرق الوقاية التقليدية من الانتكاس على الإبلاغ الذاتي والتقييمات السريرية المجدولة. وفي حين أن الإبلاغ الذاتي يسمح للأفراد بمشاركة تجاربهم؛ إلا أنه محدود بتحيزات الذاكرة والرغبة الاجتماعية والإحجام عن الكشف عن التفاصيل الحساسة؛ خصوصاً فيما يتعلق بتعاطي المخدرات. علاوة على ذلك؛ توفر التقييمات السريرية القياسية فقط لقطات متقطعة لسلوك الفرد، وتفقد التقلبات الدينامية في الوقت الفعلي في الحالة المزاجية والسلوك الاجتماعي وغيرها من التغييرات الحاسمة في تحديد مخاطر الانتكاس.

تسلط هذه القيود الضوء على فجوة كبيرة في استراتيجيات الوقاية من الانتكاس مثل: غياب البيانات المستمرة والموضوعية التي يمكن أن توفر رؤية أكثر اكتمالاً ودقة لمخاطر الانتكاس. فالاعتماد على التقارير الذاتية الدورية والفحوصات السريرية يفتقد إلى التفاصيل الدقيقة للتغيرات اليومية التي قد تشير إلى زيادة التعرض للانتكاس، مما يشير إلى الحاجة إلى نهج مراقبة أكثر قوة، مما يقدمه الذكاء الاصطناعي من المراقبة السلوكية، فيقدم الذكاء الاصطناعي بديلاً تحويلياً يعتمد على البيانات للمراقبة التقليدية؛ حيث يقدم تحليلاً مستمرًا وموضوعيًا للبيانات من مصادر مثل الهواتف الذكية والأجهزة القابلة للارتداء ووسائل التواصل الاجتماعي. ويتيح ذلك تحديد الإشارات السلوكية المرتبطة بخطر الانتكاس.

تسلط الدراسات الضوء على قدرة الذكاء الاصطناعي على مراقبة التغيرات في الحالة المزاجية والمشاركة الاجتماعية والأنشطة، مما يوفر بشكل فعال تحذيرات مبكرة لأزمات الصحة العقلية.

وتحلل خوارزميات التعلم الآلي أنماطاً مثل عدم انتظام النوم، وتقلبات المزاج، وتقدم رؤى في الوقت الفعلي للتدخلات في الوقت المناسب، كما تدعم المراقبة المستندة إلى الذكاء الاصطناعي التعافي من اضطراب استخدام القنب (CUD) من خلال تقديم ملاحظات فورية ومخصصة. من خلال معالجة قيود الطرق التقليدية، يدمج الذكاء الاصطناعي تحليلات البيانات المستمرة.

وتستند الدراسة على خلفية أن الوقاية من الانتكاس في تعاطي الحشيش (القنب)؛ حيث يعد اضطراب استخدام القنب (CUD) مشكلة واسعة الانتشار، ويعتبر القنب أكثر المخدرات غير المشروعة استخداماً على مستوى العالم عام ٢٠١٤، نحو ٩-١٠٪ من مستخدمي القنب يطورون الاعتماد، وغالباً ما يواجه أولئك الذين يحاولون الإقلاع عن التدخين معدلات انتكاسة تتجاوز ٥٠٪ خلال السنة الأولى من العلاج. (Hasin et al. 2016)، وتساهم عوامل مختلفة في الانتكاس لدى الأفراد المصابين بـ CUD، بما في ذلك التأثيرات البيئية والنفسية والسيولوجية. وتعد الضغوط والعزلة الاجتماعية والحالات النفسية المتزامنة مثل القلق أو الاكتئاب وتاريخ تعاطي المخدرات تنبؤات مهمة بالانتكاس، وعلى الرغم من الفهم الأفضل لعوامل الخطر هذه؛ فإن برامج الوقاية من الانتكاس لا تزال محدودة، لا سيما في قدرتها على مراقبة الإشارات السلوكية في الوقت الفعلي، وتعتمد الأساليب التقليدية مثل العلاج المعرفي السلوكي، (CBT)، والمقابلات التحفيزية (MI) على الإبلاغ الذاتي بأثر رجعي والتقييمات السريرية الدورية، والتي قد تفوت اللحظات الحرجة حيث يمكن أن يحدث الانتكاس. وهذا يسلط الضوء على الحاجة إلى أساليب مراقبة أكثر دينامية واستمراراً مثل تلك التي يتيحها الذكاء الاصطناعي للكشف عن العلامات المبكرة للانتكاس، فالإشارات السلوكية كمؤشرات على الانتكاس أظهرت الأبحاث أن التغيرات في الحالة المزاجية والمشاركة الاجتماعية وأنماط النوم والنشاط البدني يمكن أن تكون بمثابة إشارات

سلوكية تتنبأ بالانتكاس لدى أولئك الذين يحاولون الإقلاع عن الحشيش، كما أن الرغبة الشديدة والتعرض للإشارات المتعلقة بالمخدرات، سواء الداخلية (مثل المحفزات العاطفية) أو الخارجية (مثل المواقف الاجتماعية)، هي تنبؤات موثقة جيداً للانتكاس في اضطرابات تعاطي المخدرات (SUDs) (Vafaie & Kober,2020)، وقد أبرزت مراجعة منهجية أجراها Vafaie و Kober لأكثر من ٢٣٧ دراسة أن كلا من الإشارات البيئية والداخلية تؤدي إلى الرغبة الشديدة، مما يؤدي إلى تغيرات فسيولوجية تزيد من خطر الانتكاس، وتم العثور على تقييمات الرغبة الشديدة في الوقت الفعلي باستخدام التقييم اللحظي البيئي (EMA) للتنبؤ بدرجة كبيرة بالانتكاس، مما يشير إلى أن التقييمات الفورية في الوقت الحالي قد توفر بيانات أكثر دقة من التقارير بأثر رجعي (Vafaie & Kober,2020) في سياق تعاطي الحشيش (الغضب)، تشمل العوامل المهمة للانتكاس زيادة مستويات التوتر واضطرابات النوم والعزلة الاجتماعية (Morris et al.,2021).

يمكن مراقبة هذه المؤشرات في الوقت الفعلي من خلال الأجهزة القابلة للارتداء أو تطبيقات الأجهزة المحمولة، مما يوفر فرصة للتدخل المبكر، بالإضافة إلى ذلك، ثبت أن الاستجابات الفسيولوجية مثل التغيرات في معدل ضربات القلب وتوصيل الجلد ترتبط بالرغبة الشديدة واحتمالية الانتكاس (Bedi et al.,2014)، بالنظر إلى أن الرغبة الشديدة والإشارات السلوكية قد تتقلب على مدار اليوم؛ فإن التتبع في الوقت الفعلي يمكن أن يوفر رؤى قيمة حول رحلة تعافي الشخص.

مصادر البيانات والإشارات السلوكية: يستفيد الذكاء الاصطناعي من تطبيقات الأجهزة المحمولة والأجهزة القابلة للارتداء ووسائل التواصل الاجتماعي للمراقبة في الوقت الفعلي لمنع انتكاسة اضطراب تعاطي القنب (CUD)؛ تطبيقات الهاتف المحمول: لجمع التقارير الذاتية وتقييمات الحالة المزاجية والرغبة الشديدة وأنماط النوم ومستويات القلق. وتتعب مستشعرات الهواتف الذكية النشاط والاتصالات والمواقع لتحديد إشارات الانتكاس؛ الأجهزة القابلة للارتداء: توفير بيانات عن النشاط وجودة النوم وتقلب معدل ضربات القلب وتوصيل الجلد والإشارة إلى الضيق أو الرغبة الشديدة؛ وسائل التواصل الاجتماعي: تستخدم البرمجة اللغوية العصبية لتحليل المنشورات والردشات للحالات العاطفية ومؤشرات التوتر.

### **الإشارات السلوكية الرئيسية**

- تغيرات المزاج: القلق أو التهيج أو الاكتئاب يزيد من خطر الانتكاس.
- المشاركة الاجتماعية: يشير الانسحاب من شبكات الدعم إلى الضعف.
- النشاط البدني: يشير التراجع المفاجئ أو اضطراب النوم إلى الضيق.

• الرغبة الشديدة: السلوك المبلغ عنه ذاتيا أو الملاحظة الذي يبحث عن إشارات القنب. تستخدم الذكاء الاصطناعي نماذج تحليل الذكاء الاصطناعي تقنيات مثل التعلم الآلي (ML) والتعلم العميق (DL) ومعالجة اللغة الطبيعية (NLP) لتحليل البيانات السلوكية والتنبؤ بمخاطر الانتكاس: تصنف الخوارزميات مثل الغابات العشوائية و SVM و k-NN الأنماط السلوكية المرتبطة بالانتكاس باستخدام البيانات السابقة، مما يحسن التنبؤات بمرور الوقت مع كل من البيانات المصنفة وغير المصنفة. التعلم العميق: تحلل RNNs و LSTMs بيانات السلاسل الزمنية لتحديد الأنماط طويلة المدى، وتكشف كيف تؤثر التغيرات المزاجية على مخاطر الانتكاس. معالجة اللغة الطبيعية: تفسر تقنيات البرمجة اللغوية العصبية، بما في ذلك تحليل المشاعر ونمذجة الموضوعات، البيانات النصية لاكتشاف الحالات العاطفية السلبية والسلوك المحفوف بالمخاطر. النمذجة التنبؤية: يجمع بين طرق الذكاء الاصطناعي المتعددة لتقييم مخاطر الانتكاس في الوقت الفعلي، مما يتيح التدخلات في الوقت المناسب. تعمل نماذج المجموعات على تحسين الدقة من خلال الأساليب المتكاملة. التدريب والتحقق تتطلب نماذج الذكاء الاصطناعي الفعالة للتنبؤ بالانتكاس مجموعات بيانات كبيرة وعالية الجودة للتدريب والتحقق من الصحة: جمع البيانات: يجب أن تتضمن بيانات العالم الحقيقي من تطبيقات الأجهزة المحمولة والأجهزة القابلة للارتداء الحالة المزاجية والمشاركة الاجتماعية وأنماط النوم والإشارات الفسيولوجية جنبا إلى جنب مع أحداث الانتكاس. تساعد البيانات الطولية في رسم خريطة المسارات السلوكية التي تسبق الانتكاس. وتستخدم بيانات التصنيف التي تعتمد على التعلم الخاضع للإشراف على البيانات المصنفة بدقة، مع تحديد أحداث الانتكاس من خلال التقارير الذاتية أو التقييمات السريرية أو العلامات السلوكية مثل الرغبة الشديدة أو الانسحاب الاجتماعي. وتم التحقق من صحة النموذج وموثوقيته.

### كيف يكتشف الذكاء الاصطناعي هذه الإشارات؟

يحلل الذكاء الاصطناعي البيانات السلوكية والفسيولوجية من تطبيقات الأجهزة المحمولة والأجهزة القابلة للارتداء ووسائل التواصل الاجتماعي لتحديد أنماط الانتكاس: العزلة الاجتماعية: يكتشف التعلم الآلي انخفاض نشاط الاتصال وتحديد الموقع الجغرافي، مما يشير إلى الانسحاب من الشبكات الاجتماعية، وهو عامل خطر رئيسي للانتكاس (Torous et al. 2020).

**أنماط النوم:** تحلل نماذج التعلم العميق مثل RNNs و LSTMs بيانات الأجهزة القابلة للارتداء بحثاً عن اضطرابات النوم أو المخالفات المرتبطة بالتوتر والرغبة الشديدة. تعمل الإشارات المدمجة مثل معدل ضربات القلب ومراحل النوم على تحسين الدقة. (Sato et al. 2019)

**تتبع الحالة المزاجية:** تحلل أدوات البرمجة اللغوية العصبية وسائل التواصل الاجتماعي وبيانات اليوميات لاكتشاف المشاعر السلبية أو الكلمات الرئيسية المتعلقة بالانتكاس، مثل "الرغبة الشديدة" أو "الإجهاد"، مما يسלט الضوء على الضيق العاطفي. (Koutsouleris et al. 2018)

**الأنماط الفسيولوجية:** يفحص الذكاء الاصطناعي تقلب معدل ضربات القلب، وتوصيل الجلد، ومستويات النشاط لتحديد الإثارة المرتبطة بالإجهاد، مما يشير إلى زيادة خطر الانتكاس (Bedi et al. 2014). وخلصت الدراسة إلى أن الذكاء الاصطناعي يوفر إمكانات كبيرة لتعزيز الوقاية من الانتكاس للأفراد الذين يتعافون من اضطراب استخدام القنب (CUD) على عكس الطرق التقليدية، يتيح الذكاء الاصطناعي المراقبة المستمرة والموضوعية من خلال تحليل البيانات من الهواتف الذكية والأجهزة القابلة للارتداء والمصادر الرقمية لاكتشاف الأنماط السلوكية، مثل الحالة المزاجية والمشاركة الاجتماعية والنشاط والنوم المرتبطة بمخاطر الانتكاس، يمكن لنماذج التعلم الآلي تقديم تدخلات مخصصة في الوقت المناسب لدعم التعافي (Chrisweena Jerusha E & Saranya T.S. (2024).

## خاتمة

على الرغم من التقدم المحرز في مجالات تطبيق الذكاء الاصطناعي في المجال الطبي بوجه عام وتعاطي المخدرات على وجه الخصوص؛ فإن المشكلات التي تحيط بتجويد النماذج المقدمة والتي يجتهد العلماء من مختلف التخصصات في ابتكارها وتجريبها فإننا نرى كثراً من أوجه القصور في مسألة تعميم الاستخدام وتخطى حواجز الفئات العمرية، والاجتماعية، والثقافية، والأخلاقية، فليس لدينا حتى الآن نموذج شامل يتفق عليه أغلب العلماء لتقديم المعالجات؛ خصوصاً أن الطموحات جامحة في تصوراتها للحصول على الضبط الشامل الذي يمكن أن يتخطى كل المعايير ولو على مستويات جغرافية معينة، وذلك لأسباب موضوعية تتعلق بطبيعة البيانات التي تستخدم في اختبار النموذج، ومدى تجانسها، وإحاطتها، ومعدلات متابعة التغيير فيها، وكيفية زيادة الموثوقية والصدق الظاهري والتنبؤي لها واجتيازها معايير الجودة الإحصائية للنماذج المستخدمة فضلاً عن نوعية الخوارزميات المناسبة التي تتناسب البيانات وتنجح في التعامل معها، وفي النهاية زيادة التكلفة المالية التي يتطلبها ابتكار تلك النماذج وتنفيذها.

## المراجع

- فؤاد، هند؛ مصطفى، أميرة؛ المنشاوي، محمد. (٢٠٢٣). الذكاء الاصطناعي وتداعياته الاجتماعية والإعلامية والقانونية: رؤية استشرافية. آفاق عربية وإقليمية، الهيئة العامة للاستعلامات، القاهرة، ١١٠-١٣٨.
- عبد اللطيف، ماهر. (٢٠٢٤). الذكاء الاصطناعي في الرعاية الصحية. المركز العربي للتأليف وترجمة العلوم الصحية (١٩٧) سلسلة الثقافة الصحية.
- تقرير المخدرات العالمي. (٢٠٢٣). وثيقة ٢٣.٧-١١٩٠٨-٢٣.٧ (A)، ١٠-١٤.
- الهيئة السعودية للبيانات والذكاء الاصطناعي. (٢٠٢٤). معجم البيانات والذكاء الاصطناعي، انجليزي - عربي، الطبعة الثانية، صفحات متعددة.
- Abdelilah Elhachimi, Mohamed Eddabbah, Abdelhafid Benksim, Hamid Ibannid, Mohamed Cherkaoui,(2025) Artificial intelligence model for the prediction of cannabis Addiction, International Journal of Public Health Science (IJPHS) 14, (2), 1076-1087.
- Anthony Elliott, (2022).The complex systems of AI Recent trajectories of social theory. In Anthony Elliott,(Editor) (2022). The Routledge Social Science Handbook of AI, Routledge, 3-16.
- Chrisweena Jerusha E & Saranya T.S.(2024). AI-DRIVEN BEHAVIOURAL CUES FOR PREVENTING CANNABIS RELAPSE: A NEW ERA IN ADDICTION RECOVERY, Journal of Emerging Sciences and Applied Technologies (JESAT), 1( 1), 52-60.
- Debleena Paulz, Gaurav Sanapz, Snehal Shenoyz, Dnyaneshwar Kalyane, Kiran Kalia and Rakesh K. Tekade (2021)Artificial intelligence in drug discovery and development, Elsevier , Drug Discovery Today, 26 (1), 80-93.
- Emmanuel Kuntsche, Maree Patsouras, Zhen He, and Benjamin Riordan, (2025).Artificial Intelligence in Substance Use Research, IN Ingmar H.A. Franken, Reinout W. Wiers,Katie Witkiewitz,(Eds.)(2025).The Sage Handbook of Addiction Psychology, sage, 609-631.
- Filbey, Francesca M.(2019). The neuroscience of addiction, Cambridge ,2019, 1-20.
- Hebb, D. O. (1994). The Organization of Behavior A NEUROPSYCHOLOGICAL THEORY, John Wiley and Sons, preface.
- J. Michael Innes and Ben W. Morrison , (2022). Artificial intelligence and psychology. In Anthony Elliott,(Editor) (2022). The Routledge Social Science Handbook of AI, Routledge, 30-57.
- Jose, Jwala, and B. Suresh Kumar. “Predicting Drug Addiction in Students Using Artificial Intelligence: A Machine Learning Approach.” Shanlax International Journal of Arts, Science and Humanities, 12 (2), 138–45.
- Klaus Schwab (2016). The fourth industrial revolution, World Economic Forum, 7-17.
- Majid Afshar, Brihat Sharma, Dmitriy Dligach, Madeline Oguss, Randall Brown, Neeraj Chhabra, Hale M Thompson, Talar Markossian, Cara Joyce, Matthew M Churpek, Niranjana S Karnik, (2022)Development and multimodal validation of a substance misuse algorithm for referral to treatment using artificial intelligence (SMART-AI): a retrospective deep learning study, Lancet Digit Health. 4(6), 426–435.
- Magnus von Knebel Doeberitz,(2022).Human and Artificial Intelligence in Medicine,(2022) In Rainer M. Holm-Hadulla, Michael Wink, Joachim Funke (eds.) (2022). Intelligence Theories and Applications, Springer Nature Switzerland,273-282.

Pulkit Verma, Hemant Kushwaha, and Harpreet Singh(2023). Artificial Intelligence in Health care: nherent Biases and Concerns, In D. K. Yadav and A. Gulati (eds.), (2023).Artificial Intelligence and Machine Learning in Health-care, Springer Nature Singapore Pte Ltd, 179-187.

mhealthmarket/analysis-industry/com.grandviewresearch.www//:https)

Saif Al-Deen H. Hassan, Mohammed Kareem, Mohammad Sammany and Shaima R. Banoon (2024) Artificial Intelligence as a Predictive Tool in Drug Addiction: A Comprehensive Review, Journal of Misan Researches, 19 (39), 190- 239.

Wu Y, Ma L, Li X, Yang J, Rao X, Hu Y, Xi J, Tao L, Wang J, Du L, Chen G and Liu S (2024) The role of artificial intelligence in drug screening, drug design, and clinical trials. Front. Pharmacol. 15, 1459954, 1-12.

#### **Abstract**

### **Artificial Intelligence and Substance Abuse**

**Shehata Zayan**

This paper presents a study of what artificial intelligence can offer in the field of psychoactive substances that cause a state of dependence. The paper presents the efforts in which artificial intelligence is used, its implications for the social sciences, and the various developments accelerating research in this context. It also presents the relationship between general human intelligence and recent developments in its understanding, such as those presented by Donald Hebb. The Research presents the stages of drug detection and monitoring of their uses in the public health field, and in the field of Drug addiction and other substances. The Study Shows a number of models used in detecting and predicting the use of substances such as cannabis (hashish), opium, and others. The study concludes by presenting a picture of the hoped-for future and cites extensively from the aforementioned sources to remove ambiguity and facilitate the reader's understanding of the topic.

**Key words:** drug screening, drug design, Artificial Intelligence, Health care, drug discovery, Drug Addiction, Substance Use.