الذكاء الاصطناعي والتعلّم الآلي في فيزياء الجسيمات الأولية والكونيّات

رند الفار، ماجستير في الفيزياء، معهد إزمير للتقانة، تركيا

أولاً: مقدمة

شـهدت السنـوات الأخيرة إسـهاماتٍ عظيـمةً للذكاء الاصطنـاعي Artificial Intelligence والتعلّـم الآلي machine learning في العديـد من أركان علـم الكونيـات وفيزياء الجسيمـات الأولية أو فيزياء الطاقة العـالية، حيث بـرزت أدوات حسـابية جديـدة، ووجهات نظـر مبتكـرة حـول جمـع البيانـات، وتطويـر النماذج وتحليلها، واكتشـاف ظواهر جديـدة ضمن المعطيات، بالإضـافة إلـى ظهـور مجتمعـات ومسـارات تعليمية جديـدة. رغم التقـدم السـريع، لا تزال هنـاك إمكانات كبيـرة غيـر مستغَـلّة عنـد تقاطـع الفيزيـاء -خصوصًا علـم الكونيات وفيزيـاء الجسيمـات الأولية- مع الذكاء الاصطناعي والتعلّم الآلي. نستعرض في هذه المقالة بـعضَ التطورات الحالية والمستمـرة المتعلقة بتطبيق التعلـم الآلي في هذين المجـالَين، حيث نوضِّـح كيف يمـكن استخدام أسـاليب التعلّم الآلي المختـلفة، بما في ذلـك الشبكات العصبونيّة العـميقةDeep neural networks ، من أجـل تـعزيز قـدرة العلماء على تحليل البيانـات المعقـدة والهائـلة التي تولّدهـا التجـارب العلـمية الحـديثة، وتحـسين النماذج الريـاضية للكون والجسيمـات الأولية، والمسـاعدة في حـل المسـائل الفيزيـائية الصعبة

تعريف الذكاء الاصطناعي

يُعـرَّف الذكاءُ الاصطنـاعي بأنـه فـرع من فـروع علوم الحاسـوب يهتمّ بإنشـاء نظمٍ قادرة علـى تنفيذ مهامّ تتطلّب ذكاءً بشريًا، ويتضمّن بذلك تعلمَ الآلة، ومعالجةَ الـلغة الطبيـعية، والتعـرّفَ على الأنمـاط وغيرها من المجالات. يهـدف الذكاء الاصطناعي في هذا السياق إلـى تطوير نماذج وأنظمة تسـاهم في فهم وتحليل وتوقع سـلوكيات فيزياء الكونيـات والجسيمات الأولية بشكل فعال ودقيق.

ثانياً: الذكاء الاصطنـاعي في فيزياء الجسيمات الأولية

فيزياء الجسيمـات هي دراسة الجسيمات الأولية التي تشـكّل الكـون والقـوى التي تتفاعـل من خلالهـا. يمـكن وضـعُ حـدّ أعلـى لعـدد هذه الجسيمـات من خلال الدراسـات النظـريّة لهذا الفـرع من الفيزياء، كما ويمـكن اختبارها عمليا في عدة مختبرات أو مسـرِّعات للجسيمـات، من مثـل مصادم الهدرونـات الكبير[1]. على مـر العقـود، تطـورت الأسـاليب التجـريبية والنظـرية في هذا المجـال بشـكل كبير، مدعـومة بتطور تقنيات الحـوسبة وتحليـل البيانـات. في الآونة الأخيـرة، بـرز التعلـم الآلي كأداة قوية يمكنهـا التعامل مع تعقيد البيانـات والمعطيـات التي يتـم جمعهـا من تجـارب فيزيـاء الجسيمات.

تُعَـدّ فيزياءُ الجسيمات الأولية غريبة وفريدة من نوعها مقـارنةً بالمجـالات الأخرى عند تـطبيق التعلّم الآلي و الذكاء الاصطنـاعي عليهـا، و ذلـك لـسببَين رئيسَين. **الأول**، تخضـع فيزياء الجسيمـات لميكانيكا الكم، حيث يؤثِّـر عـدمُ اليقين المتأصِّـلُ في العالـم الميكانيكي الكمـومي علـى طبيعة الـحقيقة التي قـد نأمل في تعلّمهـا. فـمثلًا، في عمـلية إنتاج بـوزون هيغز[2] من تصـادم البروتونـات في أحـد المسِّـرعات ينتج تداخـل ميكانيـكي كمـوميّ بين بيانـات الإشـارة التي تمثِّل

1. الهَـدرون هو كينـونة تنجـم عن ارتبـاط كـواركَين أو ثلاثة. البروتون مثلًا هـو هَـدرون مُكـوَّن من ثلاثة كواركات

2. بـوزون هيغز هـو الجسيم الذي يعطي الجسيمـاتِ الأخرى كتلَها عند تفاعلهـا معـه. تبـرز أهميتـه في المسـرّعات، حيث لا يمـكن تعيين علامةٍ حقيقيّةٍ لحـدث فـردي عن إنتاجِـه، بينما يعتمـد احتمالُ العثور علـى مجموعة مـعينة من الجسيمات التي تظهـر في الكاشف على مـا إذا كان بـوزون هيغز موجودًا أم لا

© 2024 الجمعية العربية للفيزياء

إنتاج الجسيم (جسيم هيغز في هذا المثال) وبيانات الخلفيّة الضوضائية (تصادم البروتونات دون إنتاج بوزون هيغز)، بمعنى أنه من أجل كلِّ جسيم سوف تتداخل إشاراتٌ موافقة، فيظهر الجسيم على أنه إشارة (جسيم) وخلفية ضوضائية (بدون جسيم) في الوقت نفسِه. **الثاني**، تتميّز فيزياء الجسيمات بأدوات محاكاة دقيقة للغاية من أجل إنتاج بيانات تركيبية للتدريب، وقد تمّ تطوير هذه الأدوات بواسطة خبراء على مدى أكثر من 40 عامًا.

1. تطبيق الذكاء الاصطناعي والتعلم الآلي في فيزياء الجسيمات الأولية

يوفِّر التعلّم الآلي إمكانياتٍ جديدةً لتحليل البيانات بشكل أكثر كفاءة وفعالية. بدلاً من الاعتماد فقط على النماذج التقليدية، يمكن للتعلّم الآلي اكتشافُ أنماط وعلاقات في البيانات لا يمكن رؤيتها بسهولة باستخدام الأساليب التقليدية. على سبيل المثال، يمكن استخدام الشبكات العصبونيّة العميقة بغرض تصنيف الجسيمات بناءً على بيانات المستشعرات والكواشف، أو من أجل توقع نتائج التجارب بشكل دقيق.

مع ذلك، يواجه تطبيقُ التعلم الآلي في فيزياء الجسيمات تحديّاتٍ عديدة، مثل الحاجة إلى كميات كبيرة من البيانات للتدريب، وضمان تفسير النماذج، والتأكد من أن النتائج التي يتم الحصول عليها موثوقة وقابلة للتكرار. نتحدث في هذا القسم عن عدة تطبيقات للتعلم الآلي في مجال الجسيمات الأولية وتحديدًا في مصادم الهَدرونات الكبير.

1.1. التعلّم الموجه في فيزياء الجسيمات الأولية

يُعتبَر التعلّمُ المُوجَّه supervised learning أحدَ التطبيقات الأساسية للتعلّم الآلي في فيزياء الجسيمات. يتضمن هذا النوع من التعلم تدريبَ النماذج على مجموعة بيانات تحتوي على أمثلة مُصنَّفة مسبقًا، ممّا يسمح للنموذج بتعلّم كيفية التمييز بين الأنماط المختلفة.

في فيزياء الجسيمات، تُستخدم أساليب التعلم الموجه بشكل واسع في تصنيف الأحداث التي تُسجل في الكواشف. على سبيل المثال، يمكن استخدام الشبكات العصبونيّة العميقة لتمييز

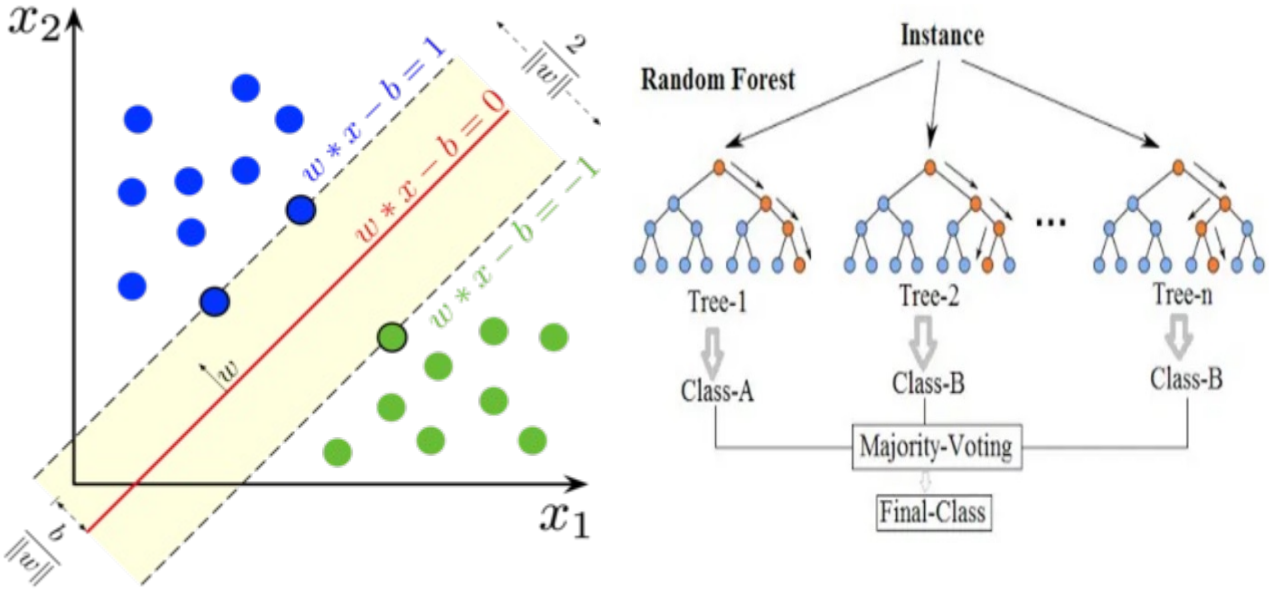

الشكل 1: (يمين) شكل تبسيطي لغابة قرارات عشوائيّة مؤلَّفة من العديد من شجرات القرار حيث يُجاوَب على سلسلةٍ من الأسئلة ما يسمح بتقديرٍ موثوقٍ للخرج النهائي المصدر. (يسار) مستوٍ فوقي hyperplane بهامشٍ أعظمي لآلة دعم متّجهي SVU تمّ تدريبُها عبر عيّنتَين من صفَّين المصدر.

© 2024 الجمعية العربية للفيزياء

الإشـارات الفيزيائية المهمّة عن الخـلفية الضوضائية. علاوة علـى ذلـك، تُستخـدم أسـاليبُ مثـل غابـات القرارات العشـوائية random decision forests وآلات الدعـم المتّجهيّة support vector machines من أجل تحديـد خصائـص الجسيمات الفـردية بناءً علـى بيانات المستشـعرات والكـواشف.

من أفضـل الأمثلة التي أظهرت نجـاح التعلّم الآلي ما يسـمى بـ " وسـم الكوارك-القاعي"، والمتمثِّل بتحديد مـا إذا كانت مجمـوعةٌ مـعينة من الجسيمـات مرتبطةً بكوارك قاعي ابتـدائي، أم لا. في التعلّم المُوجَّه، يتمّ وضـعُ جميع المسـارات المقاسة في شبـكة عصبونيّة متكـررة، ثـم يتـم تـدريب الشبـكة باستخـدام بيانات محاكاة موسـومة للتمييز بين أحداث الإشارة (كواركات قاعية) وأحـداث الخلفية (كـواركات أخرى).

قبـل التحـدث عن المثـال الجيد الثـاني، من المهم أن نفهم الطـريقة التي تعمل بها مصادمـات الجسيمات الحـديثة. في الـ LHC علـى سبيـل المثـال، من أجل تـحقيق تصادمِ مليار بروتـون في الثـانية، يتمّ تجميع الجسيمـات في حزمٍ يبـلغ عددُ كلٍّ منهـا حوالي 10^{11} بروتـون، مع حـوالي 3000 حزمة تـدور في نفق LHC في أيّ لـحظةٍ معطاة. عنـد هذه الظروف التشغيلية، قـد يصطـدم 100 بروتـون أو أكثـر في كلّ مـرة تمر فيهـا الـحزم عبـر بعضهـا البـعض، ومن بين هذه الاصطدامـات المائة، نادرًا ما تكـون هناك حادثةُ صدمٍ مباشـر حيث تصطدم الكـواركات الموجـودة داخل كل بروتـون بعضُها بعضًا بطـاقة كافية لإنتاج شيءٍ مثير للاهتمـام. عندمـا يكـون هناك صـدمٌ مباشـر -نطلق عليـه غالبًـا اسـمَ الصـدم الأوليّ primary collision- تصطـدم أيضًا بروتونات أخرى بما يُسـمّى صدمًا ثانويًّا secondary. تتفكك البروتونات المشـاركة في حوادث الصـدم الثانـوية إلـى رذاذ من البيونـات منخفضة الطـاقة نسبيًـا تتخلخل ضـمن أجهزة الـكشف. يُطلق على هذه البقايا غير المثيرة للاهتمام اسـمُ "التراكم" pileup، وبسببهـا يكـون من الصـعب تحديـدُ الطاقة الـدقيقة المشـاركة في الصـدم الأولي، مـا يُلـوِّث contaminate كلَّ قيـاسٍ تقريبًـا في الـ LHC، ولذلك من الأهـميّة بمـكان التخلّص من التراكـم عند رصد أيّ إشـارة. هناك طـرق عديدة لإزالة التراكـم مثل طريقة "طـرح المسـاحة" التي تعتمد على أن التراكـم يتألّف في الغـالب من جسيمـات منخفضة الطـاقة مـوزعة بشـكل متسـاوٍ، فيعيدَ معايرة الحدث بنـاءً على كمية الطـاقة المُـودَعة في بـعض مناطق الـكاشف التي يُعتقد أن منتجات الصدم الأسـاسي غائبةٌ فيها. هناك أيضًا طريقة "طرح الهَدرون المشـحون" التي تستخدم حقيقةَ أن الجسيمات المشحونة تترك آثارًا، بحيث يمكن مطـابقة هذه الآثـار إمّا بصـدمٍ أولي أو بآخـر ثانوي، ثـم تتـم إزالة الآثار الناجـمة عن هذا الأخير من الحدث. لا يمـكن لـكلا الطـريقتين إزالةُ جميـع أنـواع التراكم، لذلـك من الأفضـل استخدامُ طـرق الذكاء الاصطناعي الحـديثة، مثل خـوارزمية "تخفيف التراكـم"، باستخدام التعلـم الآلي لإزالتها، حيث تعتمـد على صورة الحدث فتجـري ترجـمةُ الطاقة المـودعة في منـطقة معينة من الكاشف إلى شـدة إضاءةٍ في بكسـل موافِقٍ من الصـورة. ترتكز هذه الخـوارزمية في عملها على ثلاث صورٍ متـراكبة، واحـدة (ثـانية) للجسيمات المشـحونة النـاتجة عن الصدم الأولي (الثانـوي) والأخيرة مرتبطة بالجسيمات المعتدلة الشـحنة. يتـمّ إدخال هذه الصور الثلاث في شبـكة عصبونيّة تلافيّة (CNN) تحاول إنتاج صـورةٍ رابعة تُظهـر الجسيمات المعتـدلة الناجمة من التفاعـل الأولي فقـط. يمكن تدريبُ الخـوارزمية على

© 2024 الجمعية العربية للفيزياء

بيانـات ومعطيات اصطنـاعية، حيث تكـون المعلومات الـحقيقية حول أصل الجسيمـات المعتدلة معروفة، ثم تطبيقُهـا على بيانات فعـليّة حيث لا تكون المعلومات الحقيقية عنهـا معروفة.

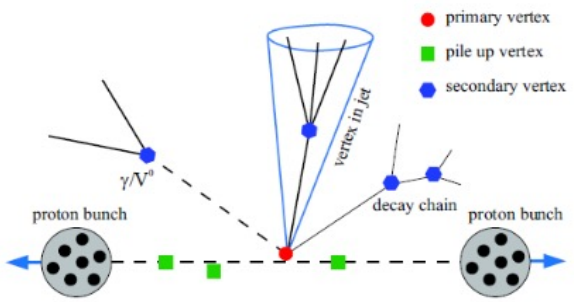

الشكل 2: أحداث صدمٍ أوّليّة وثانوية مع أحداث تراكُم المصدر.

يتطـلّب النجـاحُ في تـطبيق التعلّـم المُوجَّـه توازنًـا دقيقًـا بين تعقيـد النمـوذج وجـودة بيانـات التدريب. إذا كان النمـوذج معقـدًا جـدًا، فقد يتـسبب ذلك في تـكيّفٍ مفـرَطٍ overfitting مع بيانات التدريب وفشـلٍ في التعميـم generalization على بيانات جديدة. من نـاحية أخـرى، إذا كانت بيانـاتُ التـدريب غيـرَ كافية أو مـليئة بالانحيـازاتbias ، فإن استنتاجـاتِ النموذج قد تكون غيـرَ دقيقة.

2.1. التعلـم القائـم علـى البيانـات في فيزيـاء الجسيمـات الأولية

تمثِّـل الأسـاليب القائمة علـى البيانات اتجاهًـا ناشئًا في فيزيـاء الجسيمات، حيث يتم الاعتماد على البيانات التجـريبية من أجـل تـدريب النمـاذج بـدلاً من الاعتماد فقـط على البيانات الـحقيقية أو الاصطناعية (المُنشأة باستخدام المحـاكاة) كما في التعلُّـم المُوجَّـه. يقلِّـل هذا النـهجُ من الانحيـازات الناتجة عن الافتراضـات النظـرية، مـا يوفِّر صـورةً أكثرَ دقة للأحداث الفيزيائية.

هنـاك طريقتان للتعامل مع البيانـات في هذه الحالة. في الطـريقة الأولـى، يمكننا محاولة تـدريب الشبكة مباشـرة علـى البيانات الـحقيقية علـى الرغم من عدم نقائهـا، بينمـا في الطريقة الثـانية يمكننـا استخدامُ التعلـم الآلي لتحديـدِ مـدى تـوافق المحـاكاة مـع البيانـات، ثم محاولة تحسين المحـاكاة. على الرغم من أن البيانـات الـحقيقية في الطـريقة الأولـى لا تأتي مع تسـميات (بسبب خضوع كلّ قيـاسٍ لمكانيكا الكم، حيث يعطي كلُّ جسيم إشـارةَ جسيمٍ و إشـارةَ خلفية ضوضـائية)، يمـكن العثورُ علـى أحداث نظيفة بشـكل خـاص تـوافق إمكانيةَ إجراء التسـمية بشـكل لا لبْس فيـه -مثل رصد إشـارة الكـواركات العلـوية الواضحة- ولـكن هذه الطـريقة كانت مستخـدمة فيزيائيـا قبل التعلّـم الآلي. من أجـل تفعيـل دور التعلّـم الآلي أكثـر، يمـكن استخـدام التعلّـم ضـعيف التوجيه حيث نستخـدم التـدريب مباشـرة على عينـات مختلطة، مثل أخذ عيّنَين من حـدثَين تحـوي إحداهُمـا إشـارةَ صـدمٍ واحـدة و بـوزون z، بينما تحوي الأخرى إشـارتَي صدم؛ ومن ثـمَّ يمكن تـدريب الشبـكة العصبية للتـمييز بين هـاتين الـعينتين. يمـكن أيضًـا استخـدام التعلـم غير المُوجَّـه unsupervised learning، كمـا في JUNIPR الذي يحـاول تعلّـمَ التوزيع التفاضلي الكامـل للبيانات باستخـدام التعلم الآلي حيث يحتوي علـى بنية شبكة مبنية حـول شجـرة تجميـع ثنـائية. تُقـدِّم الشبـكاتُ

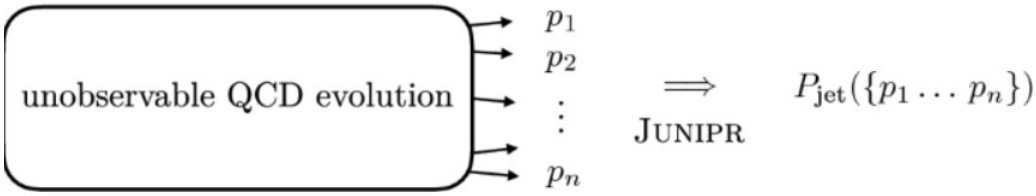

الشكل 3: يحسب JUNIPR احتماليّةَ الحصول على اندفاعاتٍ معطاة في نفثٍ دفقي تمّ اختيارُه وفق شروطٍ محدّدة تُستخدَم لتدريب البيانات المصدر.

© 2024 الجمعية العربية للفيزياء

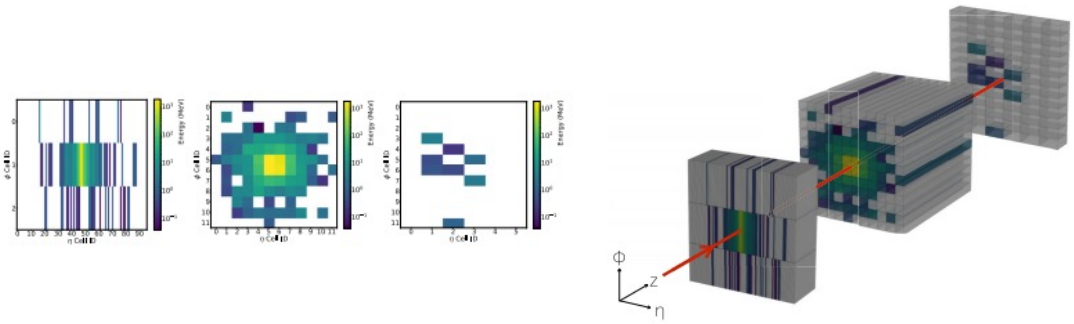

الشكل 4: (يمين) تمثيل ثلاثي البعد لحزمة بوزيترونات واردة عموديًّا على مركز الكاشِف. (يسار) تمثيل ثنائي البعد طبقيّ للحزمة السابقة. المصدر.

التوليـدية التنافسية CaloGAN مثـالًا آخرَ على التعلّم غير الموجـه، كذاك المُستخدِم شبكةً تنافسية توليدية لمحـاكاة محاكي الكاشف؛ فتقوم شبـكةٌ أولى بإنتاج أحـداثٍ وتحـاول شبكةُ خصمٍ ثانيةٌ معـرفةَ ما إذا كانت تلـك الأحـداث ناجـمةً عن الـكاشف الـحقيقي أم عن الشبـكة العصبونيّة.

يتطـلب تـطبيقُ هذه الأسـاليب تقنيـاتٍ متقـدمةً لتحـسين جـودة البيانـات المستخـدمة في التـدريب. علاوة علـى ذلـك، يتـم استخـدام تقنيـات التعلّم غير الموجـه والتعلّـم بالتمثيـل من أجـل تمـكين النماذج من استكشـاف الأنمـاط الخفية في البيانـات بـدون إشـراف مباشـر. تُظهِـر هذه الطـرقُ إمكانيّـاتٍ كبيرةً في تحـسين فهمنـا لفيزيـاء الجسيمـات، مـع تقليل الاعتمـاد على البيانـات الـحقيقية والاصطناعية. ولكن حتـى الآن، كانت التطبيقـاتُ التي تحدثنـا عنها تعنى بفيزيـاء المصادمـات فقـط، ولـكن في الواقـع يمكن تـطبيقُ الذكاء الاصطنـاعي والتعلّـم الآلي في جميع جوانب فيزياء الجسيمـات الأولية. أحد مجالات التطبيق الواعـدة للغاية هـو تحسين الحسـابات اللاضطـرابيّة لخصائـص المادة في إطار الديناميكا اللونية الكمومية الشبـكية Neural quantum chromodynamics

2. التحديـات أمـام الذكاء الاصطنـاعي والتعلـم الآلي في فيزيـاء الجسيمـات الأولية

يواجـه تـطبيقُ التعلّـم الآلي في فيزيـاء الجسيمات العديـد من التحديـات التي تتطـلب اهتمامًا كبيرًا في المستقبـل. من أبـرز هذه التحديات:

1. الشفـافية والتفسيـر: تعمـل معظـمُ النمـاذج المستخـدمة في التعلـم الآلي -وخـاصة الشبـكات العصبـونيّة العميقة- كصناديق سـوداء. يعني هذا أنه من الصـعب فهـم كيفية اتخـاذ القـرارات أو استنتاج الأنمـاط. لتـعزيز الثقة في نتـائج التعلـم الآلي، يجب تطويـر تقنيـات تُتيـح تفسيرَ النمـاذج بشـكل أفضل، مثـل الخرائط التوضيـحية التي تُظهـر العوامل الأكثر تأثيـرًا علـى النتائج.

2. الانحيـاز في البيانـات: يمـكن أن تحتـوي مجموعاتُ البيانـات المستخـدمة في التـدريب على تـحيّزات تؤثِّر على دقة النماذج. على سبيل المثال، إذا كانت البيانات تفتقـر إلـى تمثيل كافٍ لبـعض الحالات النـادرة، فقد تفشـل النماذج في التعرّف عليها بشـكل صحيح. يجب العمـل على إيجاد تقنياتٍ لتحديـد وإزالة الانحيازات من البيانات.

3. تكامـل النماذج مـع المنهجيات التقليـدية: لضمان أقصـى استفـادة من التعلـم الآلي، يجب دمجـه بـسلاسة مع الأدوات والنماذج التقليـدية المستخدمة في فيزياء الجسيمـات. يتطلب هذا الأمرُ تطويرَ أدوات تدعم التعـاون بين المنـاهج الحـديثة والتقليدية

© 2024 الجمعية العربية للفيزياء

ثالثاً: الذكاء الاصطناعي في فيزياء الكونيات

علـم الكونيات هو دراسة محتـوى وتطور الكون. وفقًا لنمـوذج ΛCDM القيـاسي لعلـم الكونيـات، يتكـون الكـون من ثلاثة مكوِّنـات رئيـسية: الطـاقة المظلمة (مصدر التوسّـع المتسـارع للكـون)، المـادة المظلمة (تشـكل غـالبيةَ الكتـلة في الكـون ويتـم استنتـاج وجودهـا عبـر التفـاعلات الثقـاليّة الجـاذبة)، والمادة العـادية المـرئية. بينمـا ظـلت البياناتُ الرصـديّةُ حتى الآن متـوافقة إلـى حـد كبير مـع النمـوذج القياسي لعلـم الكونيات، تظل هنـاك أسئلة فيزيائية أسـاسية دون إجـابة. تشـمل المجهـولاتُ طبيـعةَ الجسيمـات للمـادة المظلـمة، ومصدرَ التوسّـع المتسـارع للكون، والفيزيـاءَ التي أدت إلـى نشـوء البنـى الأولـى في الكون.

هناك احتمال مثير لحل العديد من المسـائل المفتوحة في علـم الكونيـات أو لإحـراز تقـدُّمٍ كبيـر نحـو حلِّها يكـمن في استخدام القـوة الإحصـائية التي تقدّمُها التجارب الكـونية الحالية والمستقبلية. سـوف يتطلّب تـحقيقُ العائـد العلمي الأمثـل من البيانـات القادمة أسـاليبَ قـادرةً علـى استخـراج أكبـر قدر ممـكن من المعلومـات من بين المُلاحظـات ونتـائج الرصـد، مـع التحكّم في النظم المرتبطة بالقياسـات، وفي النماذج النظـرية كذلك.

في علـم الكونيـات، ومـع زيـادة تعقيـد النمـاذج والملاحظـات بمرور الوقت، ظهرت الحـاجة إلى تحديث الأدوات المستخـدَمة لإجـراء مقارنـات صـارمة. مـع التطلـع إلى العقـد القـادم في علم الكونيـات، تُحفِّز الكميّـاتُ الهائـلة من البيانـات التي سـوف تُنتِجهـا الدراسـاتُ الاستقصائية الحـالية والقـادمة، بالإضافة إلـى التوسّـع المستمـر في نطـاق البـحث النظـري، إعـادةَ التفكيـر في الآليـات الإحصـائية المستخـدمة. ظهرت مؤخـرًا منهجيـات الذكاء الاصطنـاعي والتعلم الآلي كأدوات واعـدة لتطبيقـات علـم الكونيـات، حيث أثبتت قدرتَهـا علـى التغـلب على بـعض القيود الحسـابية المرتبـطة بالتقنيـات الإحصـائية التقليدية. يمـكن استخدام تقنيـات الذكاء الاصطناعي في تحليل البيانات الكونية الهائـلة التي تتطلب تحليلاتٍ معقدةً ودقيقة. بالإضـافة إلى ذلك، يمكن للذكاء الاصطناعي مسـاعدة العلمـاء في توقـع الظواهـر الفيزيـائية المعقـدة في الكون، ما يسـاهم في توسيع معارفنا وتقدمنـا في مجال فيزيـاء الكونيات. ومـع أن التعلم الآلي بـدأ يشـهد تبنيًـا متزايـدًا عبر مجـالات متعددة في علـم الكونيات، ولتطبيقات متنوعة، إلا أن الطبيعةَ الناشئة لهذه الأدوات تستـلزم تطويرًا دقيقًا ومتابَعةً حذرة عنـد تطبيقهـا في العلـوم، مـع إدراك تأثيرهـا المحتمـل على المجتمع بشـكل أوسـع.

وحيث كان دور الذكاء الاصطنـاعي في فيزياء الكونيات من أهـم الجـوانب التي تسـاهم في تطويـر فهمنـا للكـون وظواهـره، نستعـرض في هذا القسـم بعضَ الطرق التي أصبـحت فيها منهجياتُ التعلم الآلي جزءًا أسـاسيًا من كيفية جمـع البيانـات الكـونية وتحليلها وتفسيرها.

1. تطبيقـات الذكاء الاصطنـاعي في دراسة الكونيـات

في علـم الكونيـات، يُعـدّ تـصنيف الأنمـاط pattern classification والانحـدار regression من الأدوات الأسـاسية لتحليـل البيانـات المعقـدة النـاتجة عن عمليـات الرصـد الكـونية. يستخـدم التـصنيفُ لفصـل الأنـواع المختـلفة من الهياكل الكـونية مثل المجرات، والعناقيد المجرية galaxy clusters، وعدسات الجاذبية

© 2024 الجمعية العربية للفيزياء

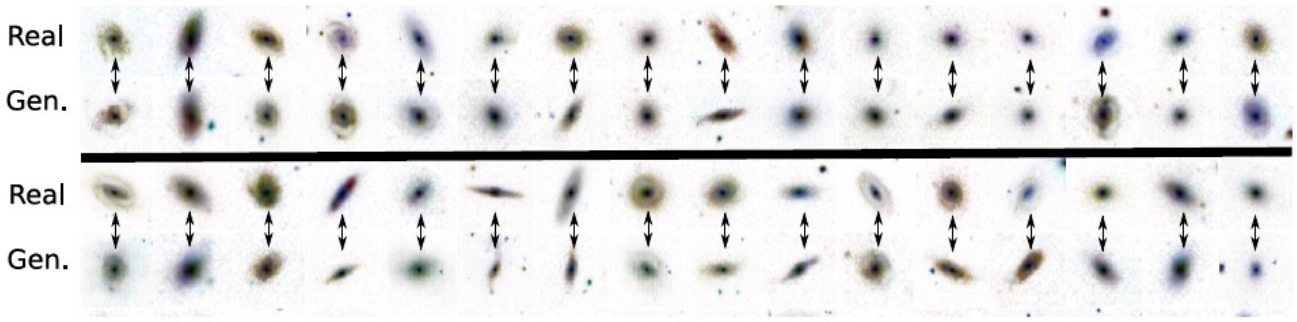

الشكل 5: عيّنة من قاعدة بيانات لمجرّات إزاء عيّنة ناجمة عن محاكاة لها باستخدام شبكات عصبونيّة. المصدر.

gravitational lens. تُستخدَم الشبكاتُ العصبونيّة التلافّية (CNNs) بشكل واسع لتحديد وتصنيف هذه الهياكل بناءً على بيانات الصور. أما الانحدار، فهو يُستخدم لتقدير المعلومات الكونية مثل الكتلة، والمسافة، ومعدّل التوسع الكوني. على سبيل المثال، تُستخدم تقنيات التعلم العميق من أجل تقدير الكتلة الديناميكية للعناقيد المجرية بناءً على الحركات الداخلية للمجرات. تمكّن هذه الأدوات من تحسين دقة القياسات وتقليل الأخطاء.

تشملُ تحديات هذا المجال تقليلَ الانحياز في النماذج الناتج عن استخدام بيانات محدودة أو غير متوازنة. لتحقيق ذلك، يتمّ تطوير نماذجَ تعلّمٍ مُوجَّه وغيرِ مُوجّه قادرةٍ على التعلّم من بيانات ضخمة وغير مُعالَجة. علاوة على ذلك، يُعد تفسير النماذج قضية محورية، حيث يسعى العلماء لفهم كيف تتعلّم النماذج من البيانات وما هي الأنماط التي تُستخدم لاتخاذ القرارات.

1.1. نماذج الانحدار في فيزياء الكونيات

ربما تكون المهمة الأكثر شيوعًا في تحليل البيانات الكونية هي استنتاجُ المُعاملات، أي وصف ما تُخبرنا به مجموعة معيّنة من الملاحظات حول مجموعة من المُعاملات ذات الدلالة الفيزيائية في نموذج معين (على سبيل المثال، المُعامِلات الستة لنموذج ΛCDM). في سياق التعلّم الموجّه، تكمن أبسطُ وأشهرُ طريقة تاريخيًا لتأطير هذه المهمة في اعتبارها مسألةَ انحدار، مثل تدريب شبكة عصبونيّة على تقليلِ متوسط الخطأ التربيعي (MSE) بين مخرجاتها ومجموعة من المُعامِلات المُستهدَفة. مع التحكم في قدرة التعبير الخاصة بالشبكة العصبونيّة وعدد عمليّات المحاكاة، يمكن إثبات أن تقليل خسارة الـ MSE يُحسِّن تقديرَ الأرجحيّة الأعظميّة (MLE)

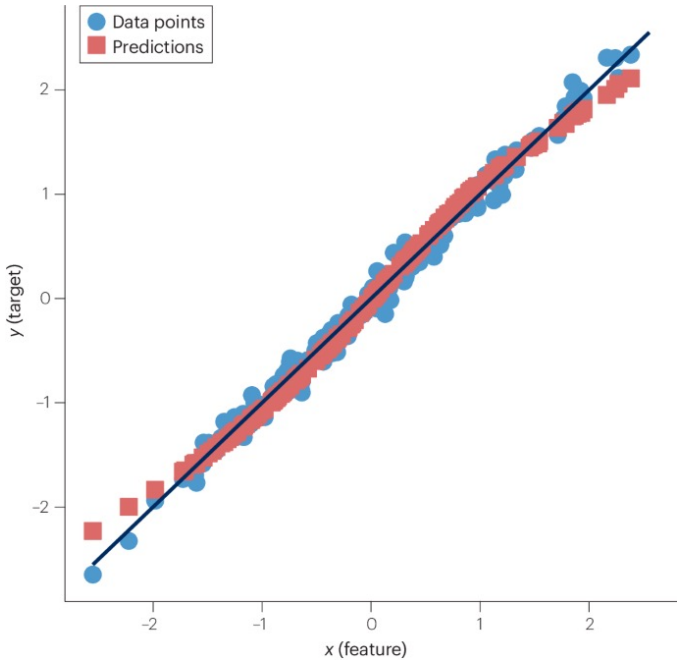

الشكل 6: يمكن استخدام تقنيات التعلّم الآلي في مسائل الانحدار والتنبّؤ بقيم معامِلات نموذج معطى المصدر.

علاوةً على ذلك، يمثّل قياسُ الانزياحِ الضوئي في علم الكونيات (Photometric Redshift) تحديًا كبيرًا لتحليل بيانات الرصد. تُستخدم هذه التقنية لتقدير مسافات المجرات بناءً على قياسات ضوئية فقط، دون الحاجة إلى الطيف الكامل. يقدِّم التعلّمُ الآلي

© 2024 الجمعية العربية للفيزياء

حلـولًا مبتكـرة لـهذه المهـمة، حيث يتـم استخـدام نمـاذج الانحـدار لتـعيين الـعلاقة بين سـطوع المجرة وألوانها وبين مسـافتها.

تشـمل التقنيـاتُ الشـائعة الشبـكاتِ العصبـونيّةَ العـميقة والنمـاذج القائمة على الغابات العشـوائية، والتي أظهرت كفـاءة عالية في تحسين دقة تقديرات الانزيـاح الضـوئي. مـع ذلـك، لا يزال هنـاك قلق من أن توزيـع بيانـات التـدريب قـد لا يكون مـمثِّلاً لتوزيع البيانـات التي سيتـم تطبيق النمـاذج عليها، من حيث أنـه لا يتـمّ إنشـاء بيانـات التـدريب من خلال محاكاة. مؤخـرًا، تـمّ العمل علـى استخدام نماذج هـرمية لبناء هيـكل سببي إضـافي في النمـاذج من أجل أن تكون أكثـرَ قـوةً أمـام هذه الاختلافـات. تهـدف النمـاذج الهـرمية إلى الجمع بين قابـلية التفسير التي توفّرها منهجيـات التـوفيق التقليـدية باستخـدام القـوالب والمـرونة التي تقدمهـا نماذج التعلـم الآلي.

تُعَـدّ عدسـات الجـاذبية أيضًا واحـدةً من أكثر الظواهر إثـارة في علـم الكونيات، حيث تنحني مسـارات الضوء القـادمة من الأجسـام البعيدة بفعل الكتـل الضخمة. هذه الظاهـرة نادرة ولكنهـا أداة قوية لدراسة توزيع المـادة المظلمة في المجـرات الضخمة، كما إنها توفّر قيـودًا قيّمةً على النمـاذج الكونية. يتطلب اكتشـافُ عدسـات الجاذبية تحليـلَ بيانات الصور الفلـكية للبحث عن أنمـاط مـميزة. يُستخـدَم التعلـمُ الآلي -وبالأخص الشبـكات العصبـونيّة التلافّيّة (CNNs)- للـكشف تلقائيًـا عن هذه العدسـات من مجموعـات بيانـات ضخـمة. بالإضـافة إلى ذلـك، يتطلب تقديـرُ معاملات العـدسة مثـل الكتـلة وتوزيعهـا استخـدامَ نمـاذج الانحدار. تُسـاعد تقنيـاتُ التعلم العـميق في تحسين دقة هذه التقديـرات عبر تحليـل الأنماط المعقدة في الصـور، ويتمّ تـدريبُ النماذج باستخـدام بيانات محاكاة وأخـرى تجريبية، ما يمكِّن من تـحقيق توازن بين الدقة والسـرعة. وبمجرد تحديد العدسات، تبدأ مهمّةُ توصيف الجسـم العدسي من خلال تقدير الأرجـحية الأعظميّة، مـا يمثِّل مسألةً حسـابية مـكثَّفة تتطـلب تحسينًا غيرَ خـطي. مؤخرًا، تـمّ استخدام الشبـكات التلافّيّة لإتمامِ تقديـرٍ سـريعٍ لمُعـاملات نمـوذج الكثـافة الإهليلجية متسـاوية الحـرارة المفـردة (Singular Isothermal Ellipsoid density profile)، والذي يُستخـدم بشـكل شـائع لنمذجة نظم العدسـات الجـاذبية القوية.

2.1. نمـاذج التعـرّف والتـصنيف في فيزيـاء الكونيـات

غـدا التنقيبُ في كـمّ البيانـات الضخـمة والمعطيـات الهائلة والتعرفُ على الأنمـاط واستخراجُها باستخدام تقنيـات الذكاء الاصطنـاعي أدواتٍ لا تقـدر بثـمن في علـم الفلـك، إذ أضـحت تمكّنهـم من غربـلة كميـات هائـلة من البيانات الرصدية وتحديد الأنماط واكتشـاف العلاقات الـمخفية داخل مجموعـات البيانات المعقدة. تلعب هذه التقنيات دورًا حاسـمًا في اكتشاف الأجرام السـماوية الجديدة وتصنيف الظواهـر الفلكية وفهم العمليات الأسـاسية التي تشـكل الكون.

تستطيع خوارزميـات الذكاء الاصطناعي، وخاصة نماذج التعلـم الآلي والتعلـم العـميق، اكتشـافَ وتـصنيف العديـد من الأجـرام السـماوية تلقائيًا، بمـا في ذلك النجـوم والمجـرات والكويكبـات والكـوازر، في الصـور الفلـكية. وقد استُخـدمت الشبكات العـصبية التلافّيّة علـى نطـاق واسـع في مسـائل اكتشـاف الأجـرام السـماوية وتصنيفها، ما مكّن علمـاءَ الفلك من تحليل المسـوحات واسـعة النطاق وفهرسة أعداد هائلة من الأجـرام السـماوية بدقة وكفـاءة عالية.

© 2024 الجمعية العربية للفيزياء

تخـوِّل تقنيـاتُ استخـراج البيانـات علمـاءَ الفلـك من تـصنيف أنـواع مختلفة من الظواهر الفلـكية بناءً على توقيعاتهـا signature وإشـاراتها المُـميِّزة الرصدية، مثـل منحنيات الضوء، والأطياف، أو التوزيعات المكانية. يمـكن لخوارزميـات التعلّـم المُوجَّـه، مثـل آلات الدعم المتّجـهي وأشجـار القـرار، تـصنيف الأحـداث العابرة، مثـل المستعـرات العظمـى supernova وانفجـارات أشـعة جامـا gamma-ray bursts والنجـوم المتغيرة variable stars، في البيانـاتِ الزمنية بـدقة عالية، ممّا يسـهل اكتشـاف ودراسة الظواهـر النادرة.

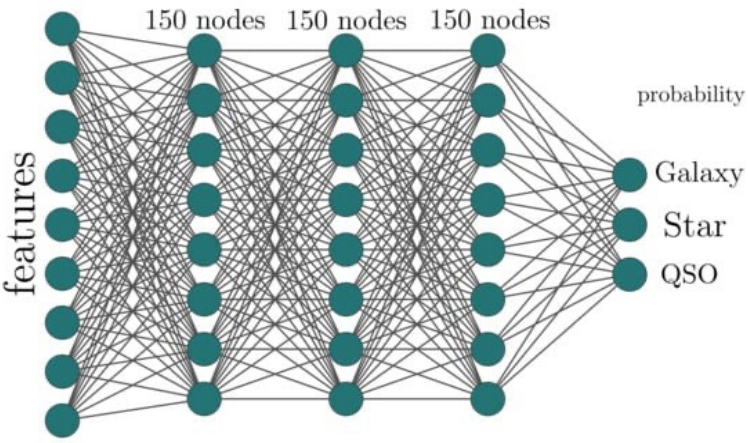

الشكل 7: نموذج شبكة عصبونيّة اصطناعيّة تُفيد في مسائل التصنيف في علوم الكون المصدر.

2. أمثلة أخرى للتعلم الآلي في فيزياء الكونيات

يفتـح التعلـم الآلي آفاقًا واسـعة في علـم الكونيات مع تطبيقـات إضافية تتضمن إعادةَ بنـاء خرائط ثلاثية الأبعـاد للمـادة المظلـمة بنـاءً على بيانات العدسـات الجـاذبية، مـا يتيـح استكشـافاتٍ أعـمقَ وأكثـر دقة للكـون. علاوة علـى ذلـك، تُستخـدم نمـاذج الانحـدار من أجـل تحليل معطيـات الخلفية الكـونية الميكروية (CMB) لتحديـد مُعـاملات النموذج الكـوني القياسي بـدقة أكبر.

2.1. تحليـل الخلفية الكونية الميكروية باستخدام التعلم الآلي

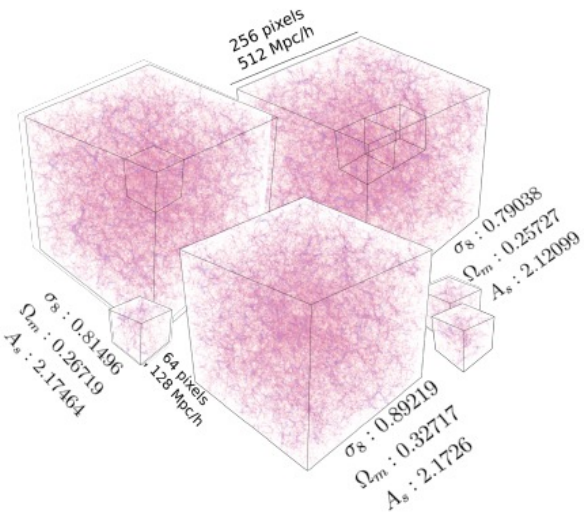

الشكل 8: توزيع ثلاثي الأبعاد للمادة المظلمة في ثلاثة مكعّبات تستخدم مجموعات متباينة من البارامترات بينما تؤدّي إلى توزيعات متشابهة تقريبًا. يقسَّم كل مكعب إلى مكعّبات جزئيّة من أجل التدريب والتنبّؤ. المصدر.

على الرغم من أن الإشـارة الأسـاسية للخلفية الكونية الميكـروية (CMB) في السيناريـو الكـوني القياسي يمـكن وصفُهـا إحصائيًـا كحقـل عشـوائي غـاوصي وتحليلُهـا بكفـاءة باستخـدام مقـدّرات طيف القـدرة الزاويangular power spectrum، إلا أن أسـاليب التعلـم الآلي أثبتت أداءً متفوقًـا في مهـامّ تحليـل الخـلفية الكونية الميكـروية، بما في ذلـك إعادة بناء تأثير العدسـات الجاذبية في الـCMB ، وفصل الإشارات الأمـامية، والاسـتـدلال باستخدام خرائـط الاستقطاب. بالنظـر إلـى التعقيد المتوقـع للبيانات، يمـكن لهذه التقنيـات أن تُـعزِّز بشـكل كبيـر المخرجـات العلـمية من المسـوحات المستقبـلية، مثـل مرصـد سيمـونز، ومشـروع CMB-S4، والتجـارب المقترحة عـالية الدقة مثـلCMB-HD . تـمّ أيضًـا استكشـاف تحليـل خرائط CMB باستخدام تقنيـات التعلم الآلي لتوصيف عناقيد المجـرات عبـر إشـارات Sunyaev–Zel'dovich وتأثيرات عدسـات الجاذبية علـى الـCMB.

2.2. استخـدام التعلـم الآلي في دراسة تطـور المـادة المظلـمة والتنبؤ بالمُعـاملات

© 2024 الجمعية العربية للفيزياء

تـمّ تدريب الشبـكات التلافّيّة ثلاثية الأبعاد على التنبؤ بالمعـاملات الكـونية الأسـاسية بنـاءً علـى التوزيـع المـكاني للمـادة المظلمة، حيث يتم تـدريب الشبكات باستخـدام محـاكاة مـكثَّفة حاسـوبيًّا من أجل دراسة تطـور المـادة المظلـمة في الكون مع افتـراض قيمٍ محـددة للمعـاملات العشـرة في نمـوذج ΛCDM الكـوني القياسي.

من الضـروري عنـد تـطبيق هذه التقنية علـى المادة المـرئية نـمذجةُ الانحيـاز والتبـاين لمؤشِّـرات المادة المـرئية بالنـسبة إلـى التوزيـع الأسـاسي للمـادة المظلـمة. من أجـل تقليـل هذه الفجـوة، تـمّ تدريب الشبـكات التلافّيّة لكي تتعلّمَ عبر خريطةٍ سـريعة بين المـادة المظلمة والمجرات المرئية، ما يسـمح بتحقيق مـوازنةٍ بين دقة المحـاكاة وتكلفتهـا الحسـابية. مع ذلك، فإن التحديات تشـمل الانحيـازات الناتجة عن قلّة الحـالات المستقـلة إحصائيًـا في المحـاكاة الكبيـرة لأنهـا مكلفة. من أجل حلّ هذه المشـكلة، يتم تطوير تقنيـات تعلّـمٍ غيـرِ موجـهة وتقنيـاتِ زيـادة البيانات (Data Augmentation) لتوسيـع نطـاق التنـوع في مجموعـات التدريب.

3.2. استخـدام التعلّـم العـميق لتقديـر كتـلة عناقيـد المجـرات

عناقيـد المجـرات هي أكبر الهياكل المرتبـطة جاذبيًا في الكـون وتعتبـر أداة قـوية لدراسة الكـون. تأتي معظـم كتـلة هذه العناقيـد من المـادة المظلـمة، التي لا يمـكن ملاحظتها مباشـرة. يمـكن تقديرُ كتل عناقيـد المجرات من خلال ظاهرة عدسـات الجاذبية، أو ملاحظات الأشـعة السينية للوسـط الداخلي للعنقود، أو عبـر التحليـل الديناميكي لمجـرات العنقود.

تـمّ أولُ استخـدامٍ للتعلم الآلي من أجـل تقدير الكتلة الديناميـكية للعناقيـد باستخـدام آلات توزيـع الدعـم support distribution machines في محـاكاةٍ تعتمـد فقـط علـى المـادة المظلـمة. كمـا وتـمّ تـطبيق العديـد من الخوارزميـات غيـر المعتمِدة على الشبـكات العصبونية، مثل الانحـدار باستخدام العمليات الغـاوصية، وآلات الدعـم المتّجـهية، وأجـهزة تـعزيز الشجـرة المتـدرّجة لحـلّ هذا النـوع من المسـائل.

رابعاً: خلاصة

تشيـر التطـورات الأخيـرة في التعلـم الآلي إلـى إمكانيات هائلة في تحـسين فهمنا لفيزياء الجسيمات وعلـوم الكـون. من خلال دمج هذه الأدوات مـع النُّهُج التقليـدية، يمـكن تـحقيق تقـدم كبيـر في تحليـل البيانـات والتنبؤ بنتـائج التجـارب.

ومـع ذلـك، فإن النجـاح المستمـر يتطـلب مواجـهة التحديات الحـالية مثل تفسير النماذج ومعـالجة التحيّز في البيانـات. يمكن للتعلـم الآلي من خلال الاستثمار في البـحث والتطويـر أن يصبـح عنصـرًا أسـاسيًا في مجمـوعة أدوات فيزيائيّي الجسيمـات والكونيات؛ الأمر الذي سيسـاعد كثيـرًا علـى حـل الألغـاز الأسـاسية للطبيعة

المراجع

1. C. Dvorkin et al., arXiv: 2203.08056
2. G. Karagiorgi et al., arXiv: 2112.03769
3. M. D. Schwartz, arXiv: 2103.12226
4. D. Bourilkov, arXiv:1912.08245
5. G. Carleo et al., arXiv:1903.10563
6. P. Adragna et al., CERN-PH-EP/2009-019
7. M. Paganini, L. de Oliveira, B. Nachman, PHYSICAL REVIEW D 97, 014021 (2018)
8. A. Andreassen, I. Feige, C. Frye and M. D. Schwartz, Eur. Phys. J. C (2019) 79:102

© 2024 الجمعية العربية للفيزياء