

التعلم الآلي والعميق : بعض الخوارزميات ودورها في الاقتصاد

د. فادي خليل * ، د. هادي خليل **

* (fadi.khalil@manara.edu.sy) كلية إدارة الأعمال، جامعة المنارة، البريد الإلكتروني:

** (hadi.khalil@manara.edu.sy) كلية إدارة الأعمال، جامعة المنارة، البريد الإلكتروني:

الملخص

تقدم هذه الورقة إضاءات على مفهوم التعلم الآلي، وتتضمن عرض مختصر عن بعض خوارزميات التعلم الآلي والعميق. ومن ثم تبين أهم النقاط المميزة والمتقدمة التي توفرها هذه الخوارزميات والتي لا تصل إليها أدوات الاقتصاد القياسي التقليدي. هذا يمهد لذكر أهم استخدامات هذه الخوارزميات في التنبؤ بالمؤشرات والمتغيرات الاقتصادية.

كلمات مفتاحية: التعلم الآلي، التعلم العميق، الشبكات العصبونية، الاقتصاد القياسي، الاقتصاد.

1. مقدمة

يعتبر التعلم الآلي أحد محطات الذكاء الصناعي والذي يهدف إلى تطوير خوارزميات تجعل الآلة تتصرف كالإنسان. ويشكل التعلم الآلي مع إصداره المعمق Deep learning قاعدة أساسية لاستخدام خوارزميات تستخدم خصائص البيانات لكي تتدرب على نموذج معين "مخبأ" ضمن هذه الخصائص وذلك تمهيداً للتنبؤ بالمرجعات المرغوبة.

وعموماً لا يقتصر مفهوم التعلم الآلي على التقنيات الحاسوبية فقط، إذ عند التعمق في أسس وتطبيقات هذا المفهوم يمكن القول أنه عبارة عن خليط متناسق بين العلوم الحاسوبية والإحصائية والرياضية، وينضوي أيضاً على مهارات برمجية وتحليلية. وأيضاً عند الإطلاع على الأدبيات المرتبطة بالتعلم الآلي يمكن الملاحظة أنّ هذا الأخير قام بالاستحواذ على العديد من الأدوات والتقنيات الإحصائية والقياسية وأضفى عليها صبغته الخوارزمية لزيادة فعاليتها وأدائها لاستيعاب بيانات ضخمة.

يوجد الكثير من خوارزميات التعلم الآلي والتي تم استخدامها في إطار العلوم الطبية، الهندسية، والاجتماعية، ولا شك إنّ استخدام هذه الخوارزميات في مجال العلوم الاقتصادية يمتلك أهمية كبيرة متمثلة بإمكانية الاستفادة من البيانات الضخمة التي تتوفر في هذا المجال وخاصة القطاع المالي. ومن جهة أخرى، يتوفر في الميدان

الاقتصادي نوعية غير تقليدية من البيانات والتي لا تشبه البيانات التي تتعامل معها الأدوات "التقليدية" للاقتصاد القياسي. من هذه الأنواع يُذكر الصور ومقاطع الفيديو والتي يمكن استخدامها بشكل فعال للتنبؤ بالعديد من الظواهر والعلاقات الاقتصادية والاجتماعية. كذلك أهمية استخدام التعلم الآلي في الاقتصاد تكمن في كم المعلومات التي تقدمها التقلبات الكثيرة التي تظهرها العلاقات الاقتصادية. هذه المعلومات تعتبر مادة خام مفيدة لأداة التعلم الآلي لكي تتعرف على خصائص البيانات وبالتالي "تتدرب" على التنبؤ بالمرجعات.

تعتمد خوارزميات التعلم الآلي على طاقم من التقنيات الرياضية والمعاملات، مثل تابع الكلفة loss function، معامل التوليف tuning parameters، معامل التعلم learning rate، خوارزمية gradient descent، قاعدة الإشتقاق chain rule، الضبط regularization، هذا الطاقم يستخدم لتقريب القيم المقدرة predicted من القيم الفعلية actual لتابع الهدف output variable، وبالتالي تساهم في تقليل أخطاء التنبؤ error prediction.

ويعتمد التعلم الآلي العميق بالإضافة إلى المفاهيم السابقة على التعامل مع حجوم بأبعاد كبيرة للبيانات من أجل اكتشاف خصائصها والتقيب على المعلومات وذلك لاكتشاف العلاقات والقواعد بين المدخلات والتقيب الأمثل لها وذلك من أجل التنبؤ

أ. خوارزمية الانحدار المضبوط **regularized regression**

تتعلق فكرة الانحدار المضبوط **regularized** من خلال ضبط مشكلة فرط التخصص **regularization** و تقليل **shrink** قيمة أو ضبط **regularize** حجم معاملات الانحدار β مما يساهم في تصغير أثر المتغيرات المستقلة غير الضرورية والناجمة عن البيئة الاقتصادية الواسعة والمتضمة في الدالة التقديرية المتعلقة بالظاهر المدروسة. بحيث يقلل من تباين النماذج المقدرّة أو يجعل أدائها جيداً في التنبؤ بقيم المتغير التابع غير الداخلة في تقدير النموذج **out of sample data**. إذ تعد هذه الخوارزمية على مبدأ المقايضة بين التحيز والتباين **Bias-variance trade off**. إذ من الأفضل النظر إلى العلاقة بين التحيز والتباين في التنبؤ على أنها مقايضة. وبشكل مبسط أكثر يُعَدُّ بمفهوم التحيز **Bias** أنّ هناك تحيز كبير في ملاءمة البيانات التي تُستخدم في التقدير أو الإستدلال (**in sample data**) على حساب بيانات أخرى لم تُستخدم في التقدير (**out of sample data**)، وبالتالي يكون الخطأ بالتنبؤ بها كبيراً وهو ما يطلق عليه بالتباين **variance**. وعلى هذه الفكرة يقوم مبدأ الانحدار المضبوط إذ أنّه من المستحيل تقليل كل من التحيز والتباين في نفس الوقت، بحيث يتسامح مع مقدار من التحيز **Bias** مقابل تقليل الخطأ في التنبؤ بالبيانات خارج العينة (تقليل التباين **Variance**). هذا التسامح في التحيز يتمثل في زيادة تابع التكلفة (مجموع مربعات الأخطاء) بتقليل ما يُسمى **panality**. يندرج تحت الانحدار المضبوط ثلاث أنواع من الخوارزميات (**Ridge, Lasso, elasticnet regression**) تختلف فيما بينها بطريقة إضافة حد التثقيل **penalty** إلى تابع التكلفة **loss function**.

ب. خوارزمية الجار الأقرب للانحدار والتصنيف **K nearest neighbors**

هي طريقة لا معلمية تستفيد من القياس الرياضي للتشابه بين خصائص المشاهدات (أو الحالات) وذلك عن طريق الحساب الرياضي للمسافات بين البيانات بغية التنبؤ بقيم المتغير التابع.

بالمخرجات. إذ يتضمن التعلم الآلي العميق إصدارات مطوّرة من الشبكات العصبونية والتي تتألف من خوارزميات تتطلب قدرة حسابية كبيرة للتعامل مع هذا الحجم من البيانات [1]، هذه القدرة توفرها العديد من منصات البرمجة مثل لغة برمجة Python و R، ومن هذه الإصدارات يُذكر خوارزميات **Convolutional Neural Network (CNN)**، **Deep Neural Network (DNN)**، **Recurrent Neural Network (RNN)**. كذلك تعتمد خوارزميات التعلم الآلي على تقنيات ومفاهيم إحصائية أساسية، مثل، متوسط مربعات الأخطاء **mean squares errors**، والانحدار **regression** والتوزيعات الإحتمالية **probability distribution**،... وعموماً تقسم أهداف الخوارزميات الآلية إلى قسمين، خوارزميات تهدف إلى التنبؤ **prediction** وخوارزميات تهدف إلى التصنيف **classification**. وتعتبر نوعية قيم تابع الهدف (**outcome variable**) عاملاً رئيسياً يحدد هدف الخوارزمية. فمثلاً إن كانت قيم تابع الهدف من النوع المستمر **continuous variable** حينها يفضل تطبيق خوارزميات التنبؤ. بالمقابل في حال كانت قيم المتغير الهدف من النوع الوصفي **qualitative** بالتالي يتم استخدام خوارزميات التصنيف للتنبؤ بفئات المتغير الهدف. ولكن هنا يتم طرح الجدلية الآتية: إن وجود تابع الهدف يعتبر من أهم مميزات خوارزميات التعلم الآلي الخاضع للإشراف **supervised machine learning**. ولكن هناك نوع آخر من الخوارزميات وهي خوارزميات التعلم الآلي غير الخاضعة للإشراف **unsupervised machine learning** التي لا تمتلك تابع هدف يقوم بالإشراف" على أداء خوارزمية التعلم الآلي. يمكن القول هنا إنّ أغلب الخوارزميات التي تندرج تحت هذا النوع من التعلم الآلي يمكن اعتبارها خوارزميات تصنيفية، كونها تقوم باكتشاف وتصنيف خصائص البيانات وبالتالي التنبؤ بالفئات التصنيفية للبيانات المتاحة.

II. أهم الخوارزميات المستخدمة في تطبيقات

التعلم الآلي في المجالات الاقتصادية:

من أهم خوارزميات التعلم الآلي والعميق المفيدة في مجال العلوم الاقتصادية يمكن ذكر:

للمخرجات المرغوبة. هذه الأوزان موجودة بين كل وصلة بين خليتين عصبيتين. إذ يؤثر هذا الوزن على كيفية معالجة الخلية العصبية للمعلومات التي تتلقاها إما عبر طبقة المدخلات أو عبر خلايا عصبية أخرى. وفي الواقع، يتمثل تدريب الشبكة العصبية الاصطناعية، بشكل أساسي على البحث عن أفضل (أو أمثل) مجموعة من الأوزان.

لا شك إن هذا التعريف المبسط والسريع للشبكات العصبونية لا يحيط بكل التفاصيل الضرورية ولكن يمكن الإضافة بالقول إن اسم هذه الخوارزمية يأتي من التشابه مع عمل الدماغ البشري الذي يتألف من بلايين الخلايا العصبية والألياف والمحاور العصبية التي تربط فيما بينها. إذ يقوم الدماغ البشري عن طريق الخلية العصبية بالنقاط المدخلات من الوسط المحيط عن طريق التشعبات العصبية dendrites، ومن ثم نقلها إلى التحليل والاستفادة من المعلومات والخبرات السابقة وذلك من خلال استخدام طبقة التحليل المتمثلة بالدالات، وبعد ذلك يتم إظهار رد الفعل (النبضة pulse) وينقله إلى باقي الخلايا العصبية الأخرى المتصلة بها عن طريق المحاور العصبية axons والتي تمثل قناة الهدف في الخلية العصبية. مما سبق يتضح أن الخلية العصبية تعمل مثل مفتاح (on/off) للإشارات الواردة عن طريق التشعبات dendrites وذلك لنقلها إلى خلايا عصبية أخرى عن طريق المحور axon. كذلك يتم التصحيح في ردة الفعل من خلال مبدأ التدريب والخطأ تمهيداً لتقليل خطأ التنبؤ لأقصى حد ممكن، وحينها يتم عرض التنبؤ من خلال طبقة المخرجات.

طبيعة عمل الدماغ البشري أنف الذكر تشبه عمل النموذج الحسائي الذي يطلق عليه اسم الشبكة العصبونية [2]. وذلك من ناحية بناءها الذي يتكون من عدد من العصبونات المتصلة فيما بينها بموصلات تنقل المعلومات والتحليل فيما بينها. وتتوزع هذه العصبونات بين الطبقات المخفية hidden layer و طبقة المخرجات. ومن مزايا الشبكة العصبونية أنها يمكن أن تستمد المعلومات من أي نوع من أنواع البيانات الرقمية سواء كانت بيانات تقليدية أو نصية أو متعددة الوسائط.

وبشكل يحاكي الدماغ البشري يتم استقبال المدخلات inputs ومن ثم معالجتها عن طريق شبكة من الأعصاب التي تنقل التحليل بين

من مجالات تطبيق خوارزمية أقرب الجيران، يُذكر علم الأحياء المجهرى لتصنيف الخلايا، وفي التسويق في تصنيف المستهلكين، وفي التصنيف الإئتماني للعملاء.

وتبرز أهمية تطبيق أسلوب KNN في هذا الميدان بأن خوارزمية KNN هي أسلوب لا معلمي لا يتطلب أي شروط مسبقة والتي تتطلبها الأساليب المعلمية في قياس العلاقات أو بناء النماذج. إذ تسمح ببناء تصنيفات من طبيعة البيانات بحد ذاتها، بمعنى آخر يكتشف أو "يتعلم" التصنيف من هيكلية البيانات ويأخذ بعين الاعتبار التغير في اتجاه هذه البيانات وتتمتع بكفاءة عالية لتقدير العلاقات غير الخطية.

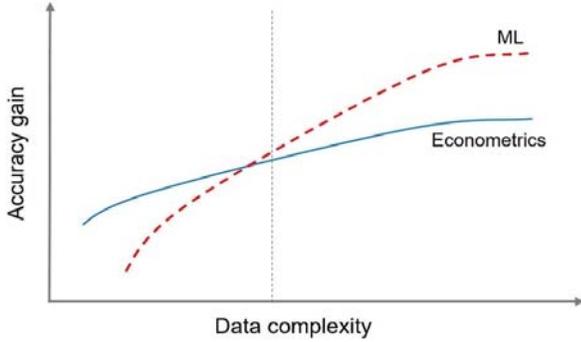
ت. خوارزمية الشبكات العصبونية Neural network.

الشبكة العصبونية الاصطناعية هي نظام حاسوبي مستوحى من الشبكة العصبية البيولوجية التي تشكل الدماغ الإنساني. "يتعلم" هذا النظام أداء المهام من خلال النظر في الأنماط المشتقة من الوسط المحيط بشكل عام دون الحاجة إلى برمجتها بأي قواعد خاصة مسبقاً. تتألف الشبكات العصبونية من مجموعة من الخوارزميات التي تقوم بتفسير البيانات الحسية من صور، أصوات، نصوص، أو سلاسل زمنية عن طريق تفكيكها إلى مفردات ومن ثم تجميعها. تتبع الشبكة العصبونية استراتيجية فرق-تسد بحيث أن كل خلية من الشبكة تختص بمعالجة جزء من المشكلة ويتم حل المشكلة الإجمالية بتجميع الحلول الجزئية [2]. تتألف الشبكة العصبونية من طبقة للمدخلات input layer تتولى التقاط المعلومات من قاعدة البيانات، ومن ثم تنتقل لمعالجتها بإحدى دالات التفعيل الرياضية activation function (الخطية أو اللاخطية) والتي تتولى إعطاء أوزان للمدخلات تبعاً لأهميتها في التنبؤ بالمخرجات، وذلك تمهيداً لاستخراج التنبؤات عن طريق طبقة المخرجات output layer. وتنتقل المعلومات والتحليل بين طبقتي المدخلات والمخرجات من خلال مجموعة من الطبقات المخفية hidden layer. في هذه الشبكة يتم تحسين التنبؤ من خلال مقارنة المخرجات مع المعلومات المتوفرة سابقاً ومن ثم محاولة تقليل الخطأ في التنبؤ عن طريق تحسين الأوزان (weights) والتي تحدد المدخلات الأكثر أهمية للوصول

التعلم الآلي في الاقتصاد يصل إلى مستوى لا يمكن أن تصل إليه تقنيات الاقتصاد القياسي التقليدية أو الكلاسيكية. ولكن المفهوم هنا ليس تنافسي بقدر ما هو تكاملي فالخوارزميات التي يعتمد عليها التعلم الآلي يتم بناءها على أساسيات الاقتصاد القياسي التقليدي ومن ثم يتم اختبار أداءها وتحسينه من خلال إدراج كم كبير من البيانات وهذا ما يمكن تحقيقه من خلال التقنيات البرمجية والحاسوبية. بمعنى آخر يمكن استخدام أساليب التعلم الآلي في تحسين أدوات القياس الاقتصادي التقليدي، وخاصة في تحسين جودة الاستدلال الإحصائي وكيفية اختيار المتغيرات التي من الأفضل أن يتم إدخالها إلى النموذج.

والعكس صحيح يمكن استخدام التعلم الآلي لتطوير تقنيات الاقتصاد القياسي التقليدي لحل مهام التقدير المرتبطة في العلوم الإجتماعية. ولكن التعلم الآلي يتميز بتقديم طريقة تنبؤية أكثر فعالية (أقل تباين).

والشكل الآتي يوضح أن مقدار الدقة في التنبؤ تزداد عموماً مع درجة تعقيد البيانات ونمذجتها، ولكن إلى حد ما تصبح بعده خوارزميات التعلم الآلي ML أنجح في تحقيق دقة في التنبؤ من أدوات الاقتصاد القياسي التقليدي.



الشكل 1. الدقة في التنبؤ مع رجة التعقيد في البيانات، مقارنة بين خوارزميات التعلم الآلي ML و أدوات الاقتصاد القياسي econometrics

المصدر : من [4]

الاقتصاد القياسي التقليدي يقوم بالتنبؤ من خلال البيانات المتوفرة ويستخدم النماذج التي ينتج عنها غالباً انحراف عن البيانات المستقبلية الحقيقية وهو ما يطلق عليه بخطأ التنبؤ. بالإضافة لذلك إن نماذج الاقتصاد القياسي مناسبة تماماً لفهم العلاقات

طبقات من العصبونات، وذلك تمهيداً لتشكيل ردة الفعل المتمثلة بصياغة المخرجات. هذه العملية يتم توظيفها في التنبؤ من خلال وجود مجموعة من المدخلات والمخرجات المحددة وبالتالي يتم القيام بمرحلتين الأولى تسمى forward propagation حيث يتم تشكيل مجموع من التركيبات الخطية بين المدخلات المحددة وذلك بشكل افتراضي للمرة الأولى. تستخدم هذه التركيبات الخطية كمدخلات لدالات تسمى activation function حيث تقوم بتنشيط العصبونات المفيدة بغية الوصول لمخرجات محددة، بعد ذلك يتم الانتقال للخطوة الثانية Back propagation حيث يتم حساب معاملات التنقيط المثلى الموزعة للمدخلات وذلك بغية الوصول للمخرجات المحددة.

وتشكل دالة Activation function الجزئية التي تمكن من أخذ اللاخطية في العلاقات الواقعية بعين الاعتبار، إذ أن الاكتفاء بدالة الجمع بين الأوزان والمدخلات لا يفي بعرض نمذجة العلاقات في الحياة الواقعية، وإن ما يجب مراعاة اللاخطية ن طريقة دالات التنشيط.

" إن قدرة الشبكات العصبية على نمذجة العلاقات المعقدة ليست نتيجة لنماذج رياضية معقدة، بل تنبثق من التفاعلات بين مجموعة كبيرة من الخلايا العصبية البسيطة." [2] pp 67.....

III. الاقتصاد القياسي والتعلم الآلي

مع ظهور العديد من الأزمات الاقتصادية والحروب والأمراض، تعرضت قدرة تفسير النماذج القياسية لتحديات كبيرة وتم اعتماد التعلم الآلي للتعامل مع كمية كبيرة من البيانات والتوسع باتجاه خوارزميات التعلم الآلي العميق للتقريب في العلاقات والنماذج والقواعد المخفية في البيانات. إذ إن تعلم الآلة يستخدم بشكل خاص لمعالجة البيانات غير التقليدية وغير المنظمة، والنقاط اللاخطية في العلاقات بين المتغيرات، و تحسين دقة التنبؤ.

فكما نوه كل من (Athey and Imbens (2019 في مقالته الأساسية " [3], 685-725، الذكاء الاصطناعي/التعلم الآلي ليس أداة فعالة لبناء النظرية ولكنه أداة أفضل للتنبؤ، إذ يسمح الذكاء الاصطناعي/التعلم الآلي بتحليل البيانات عالية الأبعاد وهو أمر يصعب تنفيذه في الأساس باستخدام الأساليب التقليدية".

المقايضة التحيز Bias والتباين variance وضبط التخصيص التحقق المتقاطع cross validation. 6. إنَّ البيانات الضخمة، نظراً لحجمها الكبير وتعقيدها، قد تتطلب أدوات معالجة أكثر قوة، وهي التي يمكن أن تقدمها تعلم الآلة [5]، إذ تسمح مجموعات البيانات الكبيرة بعلاقات أكثر مرونة لا تستطيع النماذج الخطية البسيطة التقاطها. وتتميز العلاقات الاقتصادية بكونها تفرز كمية كبيرة من البيانات اليومية وحتى اللحظية سواء في القطاع المالي أو الحقيقي. وبالتالي تطبيق خوارزميات التعلم الآلي والعميق يسمح للباحثين الاقتصاديين باكتشاف رؤى قد يكون من المستحيل الحصول عليها باستخدام التقنيات التقليدية بسبب قدرة خوارزميات التعلم الآلي على تحليل كميات هائلة من البيانات متعددة المصادر.

ما سبق يقود للقول أنَّ تقنيات تعلم الآلة مفيدة لقدرتها على نمذجة العلاقات المعقدة وغير الخطية والتي تساعد على الحصول على تفسيرات جديدة للعلاقات بين الظواهر الاقتصادية.

IV. استخدام التعلم الآلي في الاقتصاد

للتعلم الآلي دور مهم في الاقتصاد وبما إنَّ التنبؤ بالمؤشرات الاقتصادية يعتبر من أهم المساهمات للباحثين في المجال الاقتصادي، فإنَّ ذلك ينعكس على أهمية دور التعلم الآلي كونه يعتبر من التقنيات الرائدة في التنبؤ مقارنة بنماذج الاقتصاد القياسي التي تهتم بشكل أكبر بالاستدلال السببي بين المؤشرات والظواهر الاقتصادية. هذه النماذج تعاني من قصور نسبي في التنبؤ لسببين، الأول: يتمثل بعدم القدرة على حصر كل العوامل الاقتصادية في النموذج والتي تنعكس على فعالية التقدير، بينما السبب الثاني يترتب بقصور النماذج الاقتصادية القياسية أحياناً في التقاط اللاخطية والعلاقات المعقدة النابعة من الواقع الاقتصادي الحقيقي. فالنماذج القياسية قد تقوم بملاءمة بيانات العينة بتحيز كبير over identification ويجعل هذه النماذج غير فعالة وتعاني من تباين كبير في التنبؤ في البيانات غير المرئية (البيانات التي لم تم تُستخدم في التقدير).

السببية بين الجوانب المختلفة للاقتصاد، ولكن عندما يتعلق الأمر بالتنبؤ، فإنها تميل إلى "المبالغة في ملاءمة" العينات وأحياناً تعميمها بشكل سيئ على البيانات الجديدة غير المرئية. في هذا السياق، يمكن لنماذج التعلم الآلي تقليل أخطاء التنبؤ عن طريق مفاضلة التحيز والتباين. كذلك يعتبر التعلم الآلي مفيد لتعزيز أداء الطرق اللامعلمية ونصف المعلمية من خلال تجاوز مشكلة الأبعاد الكبيرة، وذلك عندما يصادف الاقتصاديين القياسيين الذين يطبقون الانحدار اللامعلمي ونصف المعلمي بيانات كبيرة جداً.

وعموماً على الرغم من أن بدايات تطوير خوارزميات التعلم الآلي تمت من قبل مبرمجين بالإشتراك مع محليي البيانات والإحصائيين، إلا أنَّ سرعان ما تمَّ توظيف هذه الخوارزميات في الأبحاث التطبيقية الاقتصادية، وذلك في محاور لا يمكن أن تصل إليها أدوات الاقتصاد القياسي التقليدية، ويمكن تلخيص هذه المحاور بـ :

1. تحليل بيانات لم تتعامل بها أدوات الاقتصاد القياسي مثل استخدام البيانات الرقمية والوسائط المتعددة من صور وفيديوهات وتسجيلات صوتية من أجل تحليل ودراسة الظواهر والعلاقات الاقتصادية.
2. التعامل مع البيانات المستمدة من بيانات غير مستقرة تنعكس على وجود علاقات ونماذج غير خطية للتنبؤ ولتمثيل العلاقة بين الظواهر الاقتصادية.
3. التعامل مع قواعد بيانات ضخمة تحتوي على الكثير من المعلومات عن خصائص المتغيرات المدروسة، وبالتالي القيام بتخفيض فرط التخصيص (over identification) الذي تقع فيه نماذج الاقتصاد القياسي في بعض الأحيان.
4. يطبق في الدرسات التي تتطلب استخدام عدد كبير جداً من المتغيرات بهدف التنبؤ بإحدى الظواهر الاقتصادية.
5. تتمكن خوارزميات التعلم الآلي من التعامل مع العلاقات المعقدة وغير الخطية المستمدة من الواقع وذلك من خلال العمل على المفاهيم التي تمَّ ذكرها سابقاً وخاصةً مفهوم

بمصطلحات اقتصادية في ملخصات وعناوين عدد كبير من الأوراق البحثية في مجلات علمية مرموقة.



الشكل 2. غيمة الكلمات word cloud للتوافق بين مصطلحات التعلم الآلي ومصطلحات الأبحاث في العلوم الاقتصادية. أشار [1] أن عدد المقالات المنشورة في إطار استخدام التعلم الآلي في الاقتصاد ازداد بمعدل متسارع يبلغ 222.4% من عام 2015 إلى عام 2021. المصدر : من [11]

٧. الخاتمة

هذه المساهمة تقدم وجهة نظر الباحثين حول تطور خوارزميات التعلم الآلي والعميق وتوظيفها في خدمة العلوم والأبحاث الاقتصادية. ولاحظ الباحثان أن العقد الماضي شهد تصاعد متزايد في عدد الأبحاث التي استخدمت خوارزميات التعلم الآلي والعميق في التنبؤ بالمؤشرات والمتغيرات الاقتصادية والمالية. وعلى الرغم من التركيز على النقاط الإيجابية في متن هذه الورقة إلا أن ذلك لا يلغي وجود سلبيات، في استخدام بعض خوارزميات التعلم الآلي، تتمثل أهمها بصعوبة تفسير الأثر وتنفيذ الاستدلال السببي من خلال هذه الخوارزميات. وأن وجهة نظر الباحثان تتمثل بأن كل من مفهوم التعلم الآلي والاقتصاد القياسي يلعبان دوراً تكاملياً وليس تنافسياً، وإن كل منهما يساهم في تحسين أدوات وأداء المفهوم الآخر. وهذا ما نراه في حقيقة أن معظم خوارزميات التعلم الآلي استندت في الأساس على مفاهيم وأدوات قياسية، رياضية، وإحصائية.....

بالتالي يمكن للتعلم الآلي في هذا المجال التنبؤ بالمؤشرات الاقتصادية الكلية مثل النمو الاقتصادي، التضخم، البطالة، مستوى الرفاهية، تخصيص الدعم والتخفيض الضريبي، ودراسة مستوى الفقر وتحديد مناطقه باستخدام الكم الهائل من البيانات الذي تزوده رقمته الاقتصاد المتزايدة، هذا جهة، ومن جهة أخرى تستطيع خوارزميات التعلم الآلي والعميق تزويد المستخدمين بتحليل نوع "غير تقليدي" من البيانات مثل البيانات متعددة الوسائط وذلك للتنبؤ بهذه المؤشرات الكلية وهذا ما تقدمه وسائل التعلم العميق مثل deep neural network، recurrent neural network RNN، convolutional neural network CNN، network DNN والتي استخدمت على نحو واسع في التنبؤ في المؤشرات الاقتصادية الكلية والنقدية [6].

كذلك خوارزميات LSTM و long short term model DNN، تستخدم على نحو واسع للتنبؤ بالأسواق المالية وتصنيف المؤسسات المالية بناء على خصائصها ومخاطرها، والتنبؤ بأسعار الأسهم، وتقييم وتحليل مستوى الائتمان المالي [7] وحركة سعر الصرف [9]، [10].

في هذا السياق باستخدام خوارزميات التعلم الآلي يمكن تحليل النماذج المخبئة في قواعد البيانات الضخمة في التقارير المالية للشركات وفي تعاملات الأسواق المالية وذلك للتنبؤ بالفشل المالي مثلاً والتعامل مع مخاطر السوق أو تحديد ملاءة طالبي القروض ومواصفات المدينين "الجديدين"، ومراقبة أداء المحافظ المالية.

من الخوارزميات المستخدمة في هذا الإطار خوارزمية أقرب جار التصنيفية k nearest neighbors والغاية العشوائية random forest، والانحدار المضبوط regularized regression. كذلك يمكن لخوارزميات الانحدار اللوجستي logistic regression وأقرب جار وشجرة التصنيف classification tree، التحليل التمييزي discriminant analysis استخدام بيانات وسائل التواصل الاجتماعي لمعرفة اتجاهات وأذواق المستهلكين والإنفاق الاستهلاكي وحركات السوق.

وفي غيمة الكلمات word cloud الآتية يظهر ترافق غزير لـ "عبارات" التعلم الآلي machine learning وبين "عبارات" ترتبط

المراجع:

- [1]. Y. Zheng, Z. Xu, and A. Xiao, "Deep learning in economics: a systematic and critical review". *Artificial Intelligence Review*, 1-43, 2023.
- [2]. J. D. Kelleher, "*Deep Learning*", (Mit Press Essential Knowledge Series), 2022.
- [3]. S. Athey, and G. W. Imbens, "*Machine learning methods that economists should know about*". *Annual Review of Economics*, 11, 685-725, 2019.
- [4]. M. Harding and J. Hersh, "*Big data in economics*". *IZA World of Labor*, 2018.
- [5]. H. R. Varian, "*Big data: New tricks for econometrics*", *Journal of Economic Perspectives*, 28(2), 2014.
- [6]. S. Galeshchuk, and Y. Demazeau, "*Forecasting hungarian forint exchange rate with convolutional neural networks*", 2017 International Conference on Behavioral, Economic, Socio-cultural Computing (BESC) (pp. 1-3). IEEE.
- [7]. B.R. Gunnarsson, S. Broucke, B. Baesens, et al. "*Deep learning for credit scoring: Do or don't?*." *European Journal of Operational Research* 295.1, 2021, 292-305.
- [8]. D. Alaminos, R. Becerra-Vicario, M. A. Fernandez-Gamez, and A. J. Cisneros Ruiz, "*Currency crises prediction using deep neural decision trees*", *Appl Sciences-Basel* 9(23):5227, 2019.
- [9]. M. F. Andrijasa, "Deep learning with encoder-decoder architecture for exchange currency rates model predictions", In A. G. Abdullah, A. B. D.
- [10]. I. W. Nandiyanto, A. A. Danuwijaya, & C. U. Abdullah (Eds.), 4th annual applied science and engineering conference, (Vol. 1402, pp. 066098). Bristol: Iop Publishing Ltd, 2019.
- [11]. A. Desai, "Machine Learning for Economics Research: When What and How?", 2023, arXiv preprint arXiv:2304.00086.