

تحديد رأي المستخدمين العرب على وسائل التواصل الاجتماعي باستخدام خوارزمية التعلم المعزز

د. جعفر سلمان *

م. فراس غانم **

(تاريخ الإيداع ٢٠٢٣/٩/٣ . قبل للنشر في ٢٠٢٣/١٠/١٢)

□ ملخص □

لا تزال الدراسات المتعلقة بتحديد آراء المستخدمين على وسائل التواصل الاجتماعي باللغة العربية ضعيفة جداً مقارنة بمثيلاتها باللغة الإنكليزية، يعتبر تحديد رأي المستخدم جزءاً أساسياً من عملية التحليل الذكي للبيانات واتخاذ القرارات، وذلك نظراً لأن رأي المستخدم يمثل تقييماً مهماً لخدمات أو منتجات الشركة، وبالتالي فإن جمع البيانات الصحيحة من المستخدمين وتحويلها إلى بيانات قابلة للتحليل يمكن أن يساعد الشركات على اتخاذ القرارات الصحيحة وتحسين استراتيجيات التسويق والتواصل مع العملاء.

تقوم هذه الدراسة بمعالجة هذه المشكلة عن طريق بناء نموذج لتحديد رأي المستخدمين من خلال تعليقاتهم على وسائل التواصل الاجتماعي مما يساعد على اكتشاف سلوكهم، وذلك وفق خوارزميات التعلم المعزز (Reinforcement Learning).

تختبر هذه الدراسة كفاءة النموذج المقترح في تصنيف سلوك المستخدمين من خلال آرائهم ضمن البيانات باللغة العربية كما تقوم هذه الدراسة بإجراء مقارنة بين نموذجنا المقترح والأعمال السابقة من خلال القدرة على تصنيف التعريجات المكتوبة باللغة العربية من البيانات على أنها إيجابية أو سلبية أو حيادية، كما تم إجراء مقارنة من خلال الزمن الذي يستغرقه كل نهج في عملية التصنيف.

تبيّن النتائج في هذا البحث التفوق الكبير الذي حققه النموذج المقترح مقارنة مع الأعمال السابقة ولا بد من الإشارة إلى القدرة الكبيرة التي يتمتع بها النموذج المقترح على تعلم كلمات جديدة وتوسيع القاموس بشكل ديناميكي وذلك بفضل توظيف خوارزمية التعلم المعزز.

الكلمات المفتاحية: سلوك المستخدمين – تعلم آلي – تعلم معزز – محتوى عربي – تصنيف.

* مدرس في قسم هندسة تكنولوجيا المعلومات – كلية هندسة تكنولوجيا المعلومات والاتصالات – جامعة طرطوس – سوريا
** طالب ماجستير في قسم هندسة تكنولوجيا المعلومات – كلية هندسة تكنولوجيا المعلومات والاتصالات – جامعة طرطوس – سوريا.

Determining the opinion of Arab users on social media using a reinforcement learning algorithm

*Dr. Jaafar Salman
**Eng. Firas Ghanem

(Received 3/9/2023 . Accepted 12/10/2023)

□ ABSTRACT

Studies related to determining the opinions of users on social media in the Arabic language are still very weak compared to their counterparts in the English language. Determining the user's opinion is considered an essential part of the process of intelligent data analysis and decision-making, given that the user's opinion represents an important evaluation of the company's services or products, and therefore collecting data Correct information from users and turning it into analyzable data can help companies make the right decisions and improve marketing strategies and communication with customers.

This study addresses this problem by building a model to determine users' opinions through their comments on social media, which helps discover their behavior, according to Reinforcement Learning algorithms.

This study tests the efficiency of the proposed model in classifying users' behavior through their opinions within the data in the Arabic language. This study also makes a comparison between our proposed model and previous works through the ability to classify tweets written in the Arabic language from the data as positive, negative, or neutral. It was also conducted Comparison of the time each approach takes in the classification process.

The results in this research demonstrate the great superiority achieved by the proposed model compared to previous works, and it must be noted that the proposed model has the great ability to learn new words and expand the dictionary dynamically, thanks to the employment of the reinforcement learning algorithm.

Keywords: user's behavior - Machine Learning – Reinforcement Learning – Arabic Content – classification

*Teacher, Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

**Master Student- Information Technology Engineering Department, Information and communication Technology Engineering, Tartous University, Syria

١- المقدمة:

شهدت شبكات التواصل الاجتماعي نمواً كبيراً في السنوات الماضية حيث يشكّل مستخدموها حوالي 81% من مستخدمي الانترنت الكليين [1]. يلج إلى هذه الشبكات مئات ملايين المستخدمين يومياً ليتواصلوا مع الأصدقاء والأحبة وليعرفوا آخر الأخبار وليحصلوا على ما يرغبون به من المعلومات وغيرها من الاستخدامات التي لا تعد ولا تحصى. تبين الإحصائيات ارتفاع عدد مستخدمي الفيس بوك (Facebook) من مئة مليون مستخدم عام 2008 حتى ملياري وأربعمئة مليون مستخدم تقريباً في الربع الثاني من عام 2019 (أي بنسبة 2400%) وذلك وفقاً لتقارير ربع سنوية ينشرها الموقع نفسه [2] وكذلك تزايد عدد مستخدمي التويتر (Twitter) بنسبة 1100% بين عامي 2010 و 2019 وفقاً لتقارير الموقع [3]. لم يكن العالم العربي بمنأى عن هذا النمو، حيث ارتفع عدد مستخدمي الإنترنت من 26 مليون مستخدم في عام 2005 ليصل إلى 173 مليون مستخدم مع نهاية عام 2017 وذلك وفقاً لإحصاءات أجراها الاتحاد الدولي للاتصالات (International Telecommunications Union) [4]. ليصل أخيراً إلى 216 مليون مستخدم في عام 2019 [5]، أي ما يقارب 50% من سكان العالم العربي. كما تدلّ الإحصاءات أيضاً على أنّ عدداً كبيراً من العرب يستخدمون شبكات التواصل الاجتماعي ليصل تغلغل هذه الشبكات إلى ما يقارب 90% من مستخدمي الإنترنت في بعض البلدان العربية [5]. على سبيل المثال، بلغ عدد مستخدمي فيسبوك في مصر حوالي 38 مليون مستخدم في عام 2019 [1].

أدى هذا التزايد بعدد المستخدمين في السنوات الأخيرة إلى تضخم هائل ومتسارع في حجم البيانات التي تنتجها شبكات التواصل الاجتماعي [1]. حيث يتم حالياً نشر حوالي 474 ألف تغريدة جديدة كل دقيقة على تويتر و ٥١٠ ألف تعليق جديد في كل دقيقة على فيسبوك و 49 ألف صورة جديدة على إنستغرام (Instagram). إنّ هذا النمو الكبير لم يكن إيجابياً بالكامل حيث أعطت السرية التي تقدّمها هذه الشبكات لمستخدميها الفرصة للعديد منهم لأن يستغلوا حرية التعبير عن الرأي بنشر ما يريدون دون أي مراعاة للآخرين أو لعواقب ما ينشرونه مختبئين وراء ألقاب وهمية، ليقوموا بالتأثير سلباً في المستخدمين الآخرين والحاق الضرر في المجتمعات الإلكترونية التي يزورونها. ما أدى بدوره إلى تضخم واضح في السلوك السلبي من عنصرية ومضايقات وتحرشات وتهديدات ونشر معلومات كاذبة، يسمّى هذا النوع من السلوك بالسلوك المعادي للمجتمع (Antisocial Behavior).

٢- هدف البحث:

تتجلى أهمية هذه الدراسة بالحاجة إلى إغناء المجتمع العلمي بالمزيد من الدراسات حول اكتشاف آراء المستخدمين العرب على شبكات التواصل الاجتماعي وذلك لقلّة الأبحاث الحالية في هذا الاتجاه. وبالتالي تهدف هذه الدراسة بشكل رئيسي إلى الوصول لخوارزمية تُستخدم في التنقيب ضمن النصوص في اللغة العربية وتحديداً في تعليقات المستخدمين لوسائل التواصل الاجتماعي واستخراج معلومات حول رأي المستخدمين تجاه مواضيع مطروحة على تلك الوسائل مع قدرة الخوارزمية على تصنيف المستخدمين إلى مجموعات بناء على معتقداتهم.

نقوم بتحقيق ذلك من خلال الأهداف الفرعية التالية:

١. تطبيق خوارزمية Proximal Policy Optimization (PPO) والتي تتدرج تحت بنود التعلّم المُعزّز Reinforcement Learning، ومدى قابلية تطبيقها على المحتوى العربي.
٢. دراسة مدى تأثير عمليات المعالجة المسبقة المختلفة لمجموعات البيانات العربية في أداء المصنّف.

٣. دراسة تأثير اللغة المستخدمة في المصنّف وأدائه.

٣- مواد وطرق البحث:

تمّ إجراء الدراسة العملية من أجل تحديد رأي المستخدمين على نصوص عربيّة مأخوذة من موقع تويتر (Twitter) باستخدام خوارزمية التّعلم المعزّز وذلك بالاعتماد على لغة بايثون البرمجية (Python) لما تقدّمه هذه اللّغة من مكتباتٍ رياضيّة ومكتبات تعلّم آليّ أثبتت جدارتها في هذا المجال.

٣-١ الدراسات المرجعية:

قام الباحثون بالعديد من الدراسات حول تحديد سلوك المستخدمين في شبكات التواصل الاجتماعي:

❖ في عام ٢٠٢٠ قامت م. ندى عاقل بنشر بحث بعنوان [1]:

"Analyzing University Students' Attitudes Through Social Media"

حيث تم في هذه الدراسة تحليل توجهات المستخدمين بالاعتماد على نهج المعجم (لأن نهج التعلم الآلي احتاج لمزيد من البيانات) وكان الهدف من الدراسة تحديد التوجه العام للطلاب بالاعتماد على النموذج المقترح، حيث أن النموذج المفترض يأخذ بعين الحسبان الرموز التعبيرية وتفاعلات المستخدمين مع المنشورات، اعتمدت الدراسة على معجم من جامعة كامبريدج وتمت ترجمته من قبل ترجمة غوغل. لكن من سلبيات الدراسة أنها اقتصرت على ٣ أنواع من المشاعر فقط (إيجابي-سلبى-محايد) بينما حقيقة المشاعر البشرية أعمق من ذلك وأيضاً من السلبيات الكبيرة لهذا النهج هي الاعتماد على مجموعة كلمات محددة وثابتة .

❖ في عام 2019 قام م. ربيع الكردي بنشر بحث بعنوان [19]:

"Detecting and modeling Anti-social behavior in social networks"

كان الهدف من الدراسة هو كشف الخطاب الذي يحض على الكراهية على وسائل التواصل الاجتماعي. تم سحب عينات من نصوص عربية وانجليزية مأخوذة من موقعي يوتيوب ١٥٠٥٠ تعليق بالعربية ومن تويتر ٢٤٧٨٣، تمت الدراسة بالاعتماد على الخوارزميات:

١. Support vector machine (SVM) وهي احدى خوارزميات التعلم الآلي.

٢. الشبكات العصبونية الالتفافية (Convolutional neural Network (CNN).

أظهرت النتائج أن خوارزمية CNN قد تفوقت على SVM من حيث F1-score و Recall و Accuracy وذلك بالنسبة للنصوص العربية والإنكليزية ولكن أتى هذا التطوير على حساب طول زمن التدريب لخوارزمية CNN.

❖ في عام 2015 قام Hossam Ibrahim بنشر بحث بعنوان [20]:

"Sentiment analysis for modern standard Arabic and colloquial"

تم في هذه الدراسة جمع ٢٠ ألف تعليق من تويتر باللغة العربية الحديثة خالية كلياً من لغة الشتائم والسخرية. تم استخدام نهج هجين قائم على المعاجم وعلى SVM.

وكان الهدف من الدراسة هو تصنيف النصوص (التعليقات) إلى ثلاثة أنواع: سلبى- إيجابي- محايد. وقد تم بناء معجمين المعجم الأول: للكلمات الحاملة للمشاعر والمعجم الثاني: للمصطلحات والتراكيب الحاملة للمشاعر كالأمثال الشعبية.

من سلبيات هذه الدراسة أنها لم تتطرق لاستخدام الرموز التعبيرية ضمن التعليق والتي بالطبع لها أثر كبير جداً على النتيجة. بالإضافة إلى أنها لم تعالج كتابة بعض الناس للتعليقات على سبيل المثال "أي لوف يو" والمقصود بها احبك. كما أن البيانات التي طبقت في الدراسة هي بيانات واضحة حيث تم حذف التعليقات التي تحوي لغة شتائم أو أي أسلوب للسخرية.

❖ في عام ٢٠٢٢ قام mohammad Yassine بنشر بحث بعنوان [19]:

"A Framework for Emotion Mining from Text in Online Social Networks"

تهدف هذه الدراسة إلى قياس قوة العلاقة بين شخصين عن طريق معالجة المنشورات والتعليقات بينهم حيث تم بناء معالج لغوية جديدة تناسب تعابير مستخدمي الويب الحديثين وتم النجاح في تصنيف التعليقات لثلاثة فئات باستخدام خوارزمية التصنيف K-means وحققت الخوارزمية نسبة نجاح في دقة عملية التصنيف تساوي إلى ٨٧%، تكمن سلبية هذه الدراسة في عدم معالجة التعليقات بناء على شكل وتركيبية الجملة وهو من المتوقع أن يحسن الأداء بشكل كبير.

٣-٢ خوارزمية التعلّم المعزز:

يتكون النموذج في التعلّم المعزز عبارة عن عميل اتخاذ القرار (Decision-Making Agent) والذي يقوم بأفعال معينة ضمن بيئة ما ويحصل إما على مكافأة أو على عقوبة وفقاً للفعل الذي يأخذه والهادف لحل مسألة ما [6]، يجب أن يتمكن من الحصول على أفضل حل بعد عدد من عمليات التجربة والخطأ (Trial and Error)، حيث يكون الحل الأفضل هو سلسلة الأفعال التي تُعظم (maximize) من المكافأة الكلية وتقلل (minimize) من العقوبة. يوضّح الشكل 3 خطوات التعلّم المعزز حيث يقوم المتعلم (الوكيل) بتوليد استجابة تقوم بإحداث تغيير ما على البيئة ومن ثم بعد حدوث التغيير على البيئة تحدد السياسة المطبقة هل يجب مكافأة أم معاقبة هذا الوكيل على القرار الذي اتخذه، ونقصد هنا بالسياسة هي تعريف أو تحديد إلى أين سيذهب الوكيل وماذا يجب عليه أن ينفذ أو يتعلم بمعنى آخر هي مجموعة الشروط التي نتوقع أن يحققها الوكيل ضمن البيئة بنجاح على سبيل المثال هل ندرّب الوكيل للمحافظة على درجة حرارة ما أم لقيادة سيارة وغيرها من الأمور التي يمكن أن تطبق من خلال الوكيل، بعد إقرار المكافأة أو العقاب من قبل السياسة سيعدل الوكيل من أداؤه وسيجنب في المرات القادمة الإقدام على نفس العمل الذي سبب له العقوبة ويتجه أكثر إلى اتجاه الإجراء الذي سبب له المكافأة وبالتالي يتولد لدى الوكيل خبرة تمكنه من العمل بشكل مناسب مستقبلاً.

من الأمثلة على مسائل يتم معالجتها باستخدام التعلّم المعزز: بناء آلة للعب الشطرنج، حيث إنّه من المكلف جداً استخدام التعلّم بإشراف وتعليم الآلة آلاف أو مئات آلاف المباريات، فضلاً عن كون الحركة الأفضل مبنية على تحركات الخصم.

في هذا البحث تم تطبيق عدد من خطوات المعالجة المسبقة على البيانات قبل البدء بعملية التدريب، وهذه الخطوات هي:

(١) **تقطيع:** تهدف هذه الخطوة إلى تقسيم النصوص الأصلية غير المعالجة في مجموعة البيانات، إلى وحدات لفظية بناءً على رموز توقّف خاصّة مثل النقطة والفاصلة وإشارة الاستفهام.

(٢) **فلترة:** يقصد بالفلترة إزالة كل الرموز الخاصّة من الوحدات اللفظية التي تمّ الحصول عليها من الخطوة السابقة والإبقاء على الحروف فقط. تتضمّن الرموز الخاصّة: التشكيل وعلامات التّرقيم والشّدات ورموزاً خاصّةً إضافية. يتمّ أيضاً إزالة جميع المحارف الرّقمية (العربية والهندية) من الواجب ذكره أنّ هذه الخطوة تختلف عن سابقتها بأنّه لا يتمّ تقسيم الوحدة اللفظية إلى وحدتين عند إزالة أحد الرموز الخاصّة. كما يتمّ إزالة كلمات التّوقف (مثل "على"، "من"، "إلى"، "و"، "أو"، وغيرها) من النصوص. تكمن الحكمة من إزالة هذه الكلمات في كونها كلمات خالية من المعلومات الدلالية التي قد تساعد في عملية التّصنيف، فضلاً عن كونها تتكرّر بشكل كبير ضمن النصوص ما يعني أنّها سوف تكون ذات أثر في المُصنّف الناتج.

(٣) **تقييس:** تُطبّق هذه الخطوة على البيانات العربية، حيث يتمّ فيها استبدال بعض الأحرف بأحرف أخرى (يتم استبدال التاء المربوطة والألف المقصورة بياء)، وتحويل الهمزات (تحوّل الهمزة على نبرة والهمزة المضمومة إلى همزة على سطر، وتحوّل كل الهمزات على ألف إلى ألفٍ ممدودة) ويعود السبب لاستخدام هذه الخطوة هو تخفيف العبء البرمجي على المتعلم.

٣-٦ النموذج المقترح

في هذا البحث سنقوم على تدريب نموذج قادر على تصنيف الرأي الموجود ضمن النصوص إلى ثلاث أصناف وهي الآراء الإيجابية، الآراء السلبية والآراء الحيادية، الهدف الحقيقي من بناء المصنّف وتدريبه وفق خوارزمية التعلم الآلي المعزز هي الحصول على معجم قادر على التدرّب أثناء عملية التّصنيف بشكل ديناميكي وبالتالي تم الاستغناء عن فكرة وجود معجم تقليدي ثابت، إن المعجم المعتمد في هذا البحث قمنا بالحصول عليه من دراسة سابقة [9] ولكن هذا المعجم كان ثابت غير ديناميكي وغير قابل للتطوير أي بمعنى آخر هو يخزن مجموعة من الكلمات ولكل كلمة وزن إيجابي أو سلبي فقط كما هو موضح في الجدول الآتي.

الجدول ١- عينة من المعجم القديم الذي سيتم استخدامه لتوليد المعجم الجديد	
الكلمة	وزن الكلمة
حب	٠.٨
كره	٠.٨٥-

في الجدول السابق يوضح وزن الكلمة بالقيمة الموجبة أنّ هذه الكلمة ذات مشاعر إيجابية أما عندما يكون وزن الكلمة سالب فهو يوضح أنّ الحالة هي مشاعر سلبية مع العلم أنّ أعظم قيمة للوزن هي ١ وأصغر قيمة هي -1.

٣-٦-١ طريقة بناء المعجم القديم:

تم الاعتماد في هذا البحث على معجم سابق لتشكل منه معجم أولي قابل للتطوير لاحقاً يسمى هذا المعجم باسم *TextBlob* ويعمل هذا القاموس على تحليل المشاعر من البيانات النصية وذلك حسب وصف الباحثين، استخدم الباحثون لبناء هذا المعجم مصنّف *Naive Bayes* مُدرّب مسبقاً لتصنيف المشاعر الخاصة بنص معين إلى إيجابية أو سلبية أو محايدة

٣-٦-١ بناء وتوسيع المعجم:

بالاعتماد على المعجم القديم الستاتيكي سيتم تطوير معجم جديد ديناميكي قادر على التعلم وإضافة كلمات جديدة بشكل آلي دون تدخل يدوي، إن آلية بناء المعجم الديناميكي الجديد تعتمد على تقنية التعلم المعزز هذه التقنية تعتمد على مبدأ المكافئة والعقاب، سنشرح في هذه الفقرة الآلية التي ستتبعها الخوارزمية في عملية التعرف والتدريب اللتان تجريان في نفس الوقت فعلى سبيل المثال عند ورود جملة جديدة إلى المصنف وبعد القيام بعمليات المعالجة الأولية سيتم تقسيم الجملة إلى قائمة من الكلمات ويتم تصنيف كل كلمة على حدا ويفرض لدينا الجملة الآتية:

شبابي

بعد تطبيق خطوات المعالجة الأولية تصبح الجملة الدخلى على الشكل الآتي:

سافر عشت طويلاً عملت بإخلاص اجد ارض وطني اشعر اسى ضاع شباب

الآن سيتم معالجة الكلمات كل منها على حدة الناتجة عن تحويل النص إلى قائمة من الكلمات وسيتم البحث عن الكلمات ضمن معجمنا الجديد والذي تم تهيئته لأول مرة بقيم المعجم القديم، يوضح الجدول -٢- نتائج البحث ضمن المعجم الجديد حيث حصلنا على القيم الآتية:

الجدول -٢- نتائج البحث عن الجملة الهدف في المعجم الجديد		
الكلمة	الوزن	ملاحظات
سافر	٠.٢٣	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
عشت	-	لم يتم إيجاد الكلمة في المعجم الجديد
طويل	0.35	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
عملت	-	لم يتم إيجاد الكلمة في المعجم الجديد
اخلاص	0.62	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
اجد	0.08	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
ارض	0.12	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
وطني	0.55	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
اشعر	0.45	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
اسى	-0.65	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
ضاع	-0.35	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد
شباب	0.5	تم إيجاد الكلمة الحصول على الوزن من المعجم الجديد

نلاحظ بعد أن تمت عملية البحث ضمن المعجم الجديد بوجود كلمتين غير موجودتين فيه بالتالي لم نحصل على وزن هاتين الكلمتين (عشت-عملت)، ومن أجل إيجاد الوزن اللازم لهما سوف يتم تفسير قيمة وزن هاتين الكلمتين بشكل مؤقت من أجل حساب متوسط وزن الجملة الكلي حيث يوضح الجدول -٣- آلية احتساب وزن الجملة.

الجدول -٣- احتساب وزن الجملة														
											المجموع	توسط الوزن		
الكلمة	عملت	عشت	سافر	طويل	اخلاص	اجد	ارض	وطني	اشعر	اسى	ضاع	شباب		
الوزن	٠	٠	٠.٢٣	٠.٣٥	٠.٦٢	٠.٠٨	٠.١٢	٠.٥٥	٠.٤٥	٠.٦٥-	٠.٣٥-	٠.٥	١.٩	٠.١٩

تشير العملية الحسابية السابقة إلى أن الجملة المدروسة هي ذات رأي إيجابي بنسبة ٠.١٦ حيث تعبر هذه النسبة عن مجموع أوزان الكلمات في الجملة بعد ذلك تقسيم المجموع على عدد الكلمات، لكن ما زال هنالك نقطة عالقة وهي الكلمتين التي لم يكن لها أي وزن " عملت " و "عشت" وغير موجودتين في المعجم الجديد الذي تم تهيئته لأول مرة من قيم المعجم القديم، بالتالي سيتم إضافة هاتين الكلمتين إلى المعجم الجديد بوزن بدائي وهو وزن الجملة ٠.١٩ ، كوزن ابتدائي تجريبي لتدخل به هذه الكلمة إلى المعجم الجديد لأول مرة ويدرجها الوكيل ككلمة ضمن قاموس الرأي الديناميكي.

الآن بعد أن تمت عملية التصنيف بشكل كامل يجب علينا أن نقوم بتحديث الأوزان من أجل تحقيق ميزة المكافئة للمتعلم المعزز، آلية المكافأة على الشكل الآتي كل كلمة كان وزنها من صنف (إشارة) الجملة سيتم زيادة وزنها بمقدار ٠.٥% وهي زيادة بمقدار بسيط يضمن أن عملية تحديث الوزن (عملية التعلم) لا تتم على شكل قفزات كبيرة بل على شكل خطوات صغيرة، وأيضاً بشرط أن لا تزيد هذه الزيادة عن عتبة ٠.٨ حيث يجب ألا يكون وزن البيانات أعلى من حد معين لأنه يمكن أن يسبب مشاكل في التخزين والمعالجة والتحليل، وأيضاً يمكن أن تستهلك كميات كبيرة من البيانات قدرًا كبيرًا من مساحة التخزين ويمكن أن تبطئ أو حتى تعطل الأنظمة[4].

يمكن أن تكون معالجة هذه البيانات وتحليلها أيضاً مكلفة من الناحية الحسابية وتستغرق وقتاً طويلاً ، مما يجعل من الصعب على المؤسسات اتخاذ قرارات في الوقت المناسب بناءً على البيانات بالإضافة إلى ذلك قد تحتوي مجموعات البيانات الكبيرة على معلومات غير ضرورية أو غير ذات صلة ، مما قد يؤدي إلى تحليلات واستنتاجات غير دقيقة، لذلك من المهم إدارة حجم ومحتوى مجموعات البيانات بعناية لضمان إدارة وتحليل البيانات بكفاءة ودقة، أما من أجل تحقيق خاصية العقوبة الخاصة بالتعلم المعزز فإن أي كلمة ضمن الجملة المدروسة لها وزن معاكس لمتوسط الجملة سيتم خفض وزنها بمقدار ٠.٥% (في المثال الذي تم طرحه سابقاً كان متوسط الجملة ٠.١٩ بالتالي أي كلمة وزنها سالب سيتم معاقبتها أي تخفيف وزنها وأي كلمة وزنها موجب ستتم مكافأتها أي زيادة وزنها)، بعد عملية التحديث فإن الأوزان ضمن المعجم الجديد ستكون وفق الجدول الآتي:

الجدول -4- الأوزان في المعجم الجديد بعد عملية تحديث الوزن (المكافأة)			
الوزن	الكلمة	الوزن	الكلمة
٠.٠٥*٠.٠٨+٠.٠٨	أجد	٠.٠٥*٠.٢٣+٠.٢٣	سافر
٠.٠٥*٠.١٢+٠.١٢	أرض	٠.٠٥*٠.١٦+٠.١٦	عشت
٠.٠٥*٠.٥٥+٠.٥٥	وطني	٠.٠٥*٠.٣٥+٠.٣٥	طويل
٠.٠٥*٠.٦٢+٠.٦٢	إخلاص	٠.٠٥*٠.١٦+٠.١٦	عملت
٠.٠٥*٠.٥+٠.٥	شباب	٠.٠٥*٠.٤٥+٠.٤٥	اشعر

الجدول -٥- الأوزان في المعجم الجديد بعد عملية تحديث الوزن (العقاب)			
الوزن	الكلمة	الوزن	الكلمة
٠.٠٥*٠.٦٥+٠.٦٥-	اسى	٠.٠٥*٠.٣٥+٠.٣٥-	ضاع

تتم آلية تحديث الأوزان وفق المعادلة الآتية والتي تضمن أن تتم عملية المعاقبة والمكافأة لجميع الكلمات وبجميع الحالات:

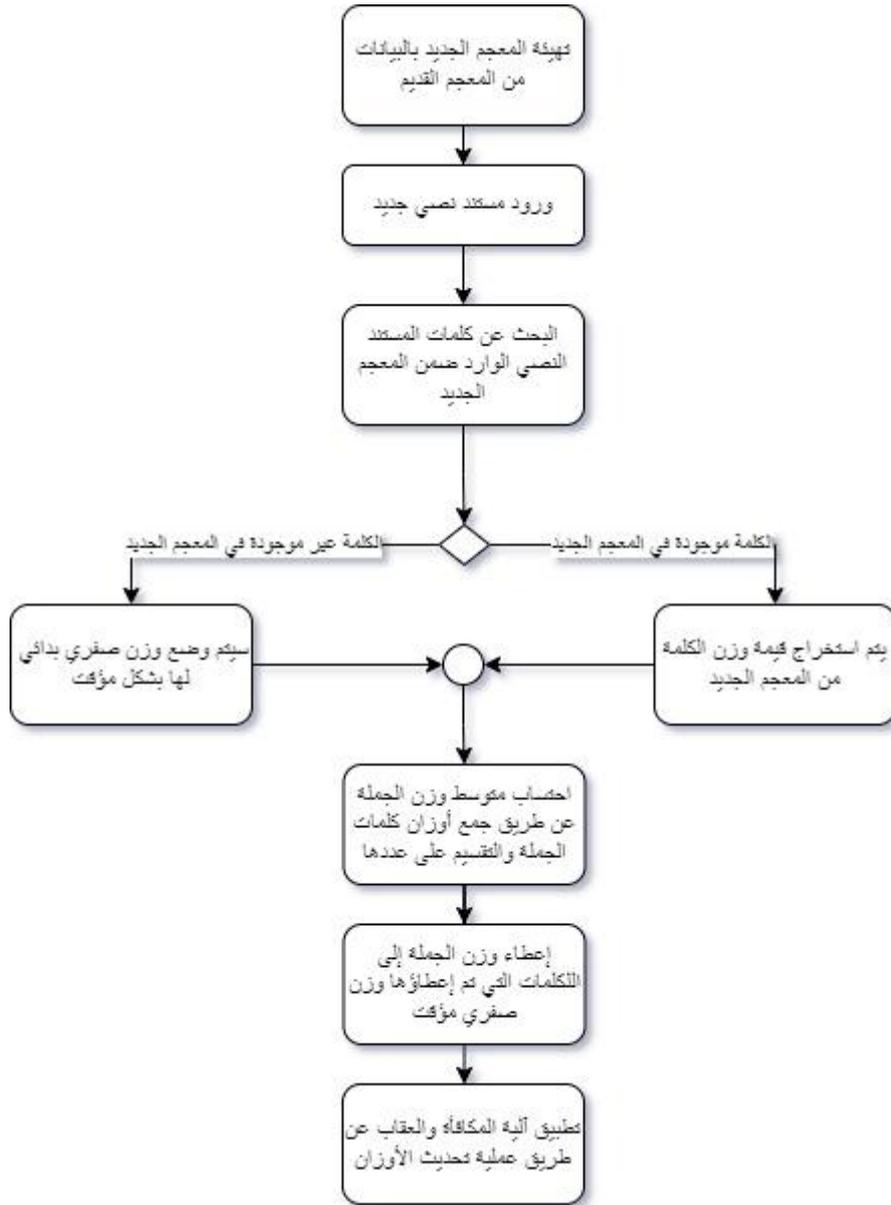
$$\text{الوزن الجديد} = \text{الوزن القديم} + \text{الوزن القديم} * ٠.٠٥$$

(١)

تم استخدام المعادلة (١) في خطوة تحديث الأوزان كونها تشكل أفضل تمثيل لآلية المكافأة والعقاب فنرى في المثال السابق كلمة "ضاع" والتي كانت قطبيتها -٠.٣٥ أي أنها ذات رأي سالب بنسبة ٠.٣٥. أما بعد التحديث أصبحت قطبيتها ٠.٣٣٢٥- هذا التحديث هو عقاب لهذه الكلمة فهي ابتعدت عن قطبيتها السالبة واقتربت بمقدار بسيط إلى القطبية الموجبة، ونرى في حالة أخرى من المثال السابق في كلمة "اشعر" والتي كانت قطبيتها ٠.٤٥ أي أنها موجبة بنسبة ٠.٤٥ وبعد التحديث أصبحت قيمة وزنها ٠.٤٧٢٥ والذي حدث هو أن الكلمة تمت مكافأتها واقتربت إلى القطبية الموجبة بشكل أكبر.

في معجمنا المطور قد يتم إدراج كلمة جديدة على أنها ذات قطبية موجبة أو سالبة ولكن قد لا تتكرر هذه الكلمة مرة أخرى في أي مستند من المستندات الواردة لاحقاً، بالتالي سنحتاج إلى وجود شكل آخر من أشكال العقاب وسيكون على الشكل الآتي فعند وجود كلمة ما لا يتم معالجتها بعد ورود ١٠ آلاف جملة سيتم خفض وزنها للنصف وهذه العقوبة تعالج حالة دخول كلمة إلى معجم الوكيل بشكل خاطئ حيث يجب في التعلم المعزز استخدام المكافأة والعقاب ويستخدمان في تقديم ملاحظات إلى الوكيل بناءً على تصرفاته، كما ذكرنا سابقاً فالمكافآت هي قيم إيجابية ممنوحة للوكيل عندما تنفذ إجراءات مرغوبة ، وتشجيعها على تعلم وتكرار تلك الإجراءات، من ناحية أخرى فإن العقوبات هي قيم سلبية تُعطى للوكيل عندما تنفذ إجراءات غير مرغوب فيها ، وتنبيهاً من تكرار تلك الإجراءات. من خلال ضبط المكافآت والعقوبات ، يتم توجيه الوكيل نحو تعلم السلوك الأمثل لزيادة المكافآت وتقليل العقوبات.

يوضح الشكل (5) عملية تطوير المعجم وتوسيعه من خلال إضافة كلمات جديدة.



الشكل ٥ - بناء وتوسيع المعجم

٣-٦-٣ النموذج المقترح مع تحليل emoji's ضمن النص

في هذا البحث لن يقتصر عملنا على تحليل النص والكلمات من أجل اكتشاف الرأي بل سيتعدى ذلك ليحلل الرسوم الكتابية أو ما تعرف ب *emoji* والتي تستخدم بشدة على وسائل التواصل الاجتماعي، هذه الرموز قد تغير سياق الكلام عند استخدامها فالجملة ذات المعنى الإيجابي قد تصبح سلبية وبالعكس تبعاً لنوع الرسوم المستخدمة، من أجل القيام بهذه العملية سيتم استخدام ما يعرف باسم "قاموس درجات المشاعر للرموز التعبيرية" [9] وهو عبارة عن قيم عددية مخصصة لكل رمز تعبيري لقياس المشاعر أو المحتوى العاطفي الذي تنقله. تساعد هذه الدرجات في تحليل مشاعر منشورات وسائل التواصل الاجتماعي وتطبيقات المراسلة والتفاعلات الأخرى عبر الإنترنت، على سبيل المثال قد يتم تعيين درجة عالية من المشاعر الإيجابية للوجه المبتسم برموز تعبيرية لعيون القلب ، بينما قد يكون للوجه العابس درجة سلبية. غالباً ما يتم تحديد درجات مشاعر القاموس للرموز التعبيرية من خلال تحليل سياق استخدامها

والمشاعر المرتبطة بها، تسمح هذه الدرجات بقياس أكثر دقة للمشاعر في الاتصالات الرقمية وتحسين دقة تحليل المشاعر. من أجل توضيح الفكرة بشكل أدق سنستخدم المثال السابق المذكور في الفقرة ٣-٥-٢ ونقوم بإضافة رمز تعبير عليه كما الآتي:

سافر عشت طويل عملت اخلاص اجد ارض وطني اشعر اسي ضاع شباب

كما ذكرنا سابقاً في الفقرة السابقة فإن هذه الجملة قد حصلت على متوسط وزن ٠.١٦، ولكن مع وجود الرمز التعبيري فسيتم التأكد من وزن الجملة للحصول على المعرفة بشكل دقيق، لاستخدام وزن الرموز التعبيرية مع قيمة المشاعر النصية يمكننا الحصول على وزن الرموز التعبيرية من الجدول ٦-٦-٦ وعند تطبيقه على مثالنا نجد الرمز (وجه بدموع الفرح) يحمل قيمة إيجابية بدرجة ٠.٥٥ وقيمة سلبية بدرجة ٠.٢ وقيمة حيادية بدرجة ٠.٢٥. فإذا كانت الرسالة تحتوي على مشاعر إيجابية للنص والرمز التعبيري إيجابي مثل الوجه المبتسم، فإن وزن الرمز التعبيري يمكن أن يزيد من الشعور العام بالرسالة، وبالمثل إذا كان وزن الجملة النصية سلبية ولكن الرمز التعبيري إيجابي، فإن وزن الرمز التعبيري يمكن أن يقلل بشكل طفيف من الشعور العام.

من أجل تطبيق تحديد الرأي باستخدام الرموز التعبيري سوف نستخدم المعادلة الآتية:

$$\text{الوزن الجديد} = W + [W * (\text{وزن الرمز التعبيري الإيجابي})] - [W * (\text{وزن الرمز التعبيري السلبى})]$$

(٢ السلبى)]

حيث W هي وزن الرأي الخاص بالجملة النصية والذي حصلنا عليه من الفقرة ٣-٦-٢ وباستخدام المعادلة (١)، وتطبيق المعادلة (٢) على مثالنا نجد التحديث على قيمة الوزن، من الجدير بالذكر أن القيمة الحيادية قمنا بحذفها من المعادلة كون قيمة الحياد هي الصفر.

$$\text{الوزن الجديد} = ٠.١٩ + [(٠.١٩ * ٠.٥٥) - (٠.١٩ * ٠.٢٥)] = ٠.٢٤٧$$

من الملاحظ أن قيمة الوزن ازدادت من القيمة ٠.١٩ إلى القيمة ٠.٢٤٧ أي أن وزن الرأي الإيجابي قد تعزز وذلك باستخدام الرمز التعبيري الإيجابي ولكن كيف سيصبح الوزن الكلي للجملة لو استخدمنا رمز تعبير آخر سلبى على سبيل المثال والذي له قيمة سلبية بدرجة ٠.٦ وقيمة إيجابية بدرجة ٠.٢٢.

$$\text{الوزن الجديد} = ٠.١٩ + [(٠.١٩ * ٠.٢٢) - (٠.١٩ * ٠.٦)] = ٠.١١٧٨$$

نلاحظ انخفاض الوزن الإيجابي للجملة والسبب هو وجود الرمز التعبيري ذو القيمة السالبة بشكل كبير.

Char	Image [twemoji]	Unicode codepoint	Occurrences [5...max]	Position [0...1]	Sentiment score				Sentiment bar (c.i. 95%)	Unicode name	Unicode block
					Neg [0...1]	Neut [0...1]	Pos [0...1]	score [-1...+1]			
😭	😭	0x1f602	14622	0.805	0.247	0.285	0.468	0.221		FACE WITH TEARS OF JOY	Emoticons
♥	♥	0x2764	8050	0.747	0.044	0.166	0.790	0.746		HEAVY BLACK HEART	Dingbats
♣	♣	0x2665	7144	0.754	0.035	0.272	0.693	0.657		BLACK HEART SUIT	Miscellaneous Symbols
😊	😊	0x1f60d	6359	0.765	0.052	0.219	0.729	0.678		SMILING FACE WITH HEART-SHAPED EYES	Emoticons
😭	😭	0x1f62d	5526	0.803	0.436	0.220	0.343	-0.093		LOUDLY CRYING FACE	Emoticons
😘	😘	0x1f618	3648	0.854	0.053	0.193	0.754	0.701		FACE THROWING A KISS	Emoticons
😊	😊	0x1f60a	3186	0.813	0.060	0.237	0.704	0.644		SMILING FACE WITH SMILING EYES	Emoticons

الشكل ٦-٦ - عينة عن أوزان الرموز التعبيرية

٤ - النتائج والمناقشة:

في هذا القسم تمّ عرض النتائج التي حصلنا عليها بعد اختبار أن قمنا باختبار النموذج على ثلاث عينات جزئية تم اجتيازها من البيانات الأساسية وذلك للمقارنة بين النهج القديم [18] والنهج الحديث المُطبّق في دراستنا هذه، إن عينات البيانات موزعة على الشكل الآتي:

- العينة الأولى مكونة من ٥٠ مستند نص جميع المستندات في هذه العينة مصنفة مسبقاً على أنها إيجابية.
 - العينة الثانية مكونة من ٥٠ مستند نص جميع المستندات في هذه العينة مصنفة مسبقاً على أنها سلبية.
 - العينة الثالثة مكونة من ٨٠ مستند نص مكونة من ٤٠ مستند نص مصنف مسبقاً على أنه إيجابي و ٤٠ مستند نص آخر مصنف مسبقاً على أنه سلبى.
- سيتم تطبيق كل عينة على النهج الجديد والقديم من أجل المقارنة وتوضيح الفروقات والنتائج بين النهجين من حيث القدرة على التصنيف والدقة في الحصول على النتائج.

	Positive	Negative	Neural
Positive	True Positive Positive	False Negative Positive	False Neural Positive
Negative	False Positive Negative	True Negative Negative	False Neural Negative
Neural	False Positive Neural	False Negative Neural	True Neural Neural
	Positive	Negative	Neural

	Positive	Negative	Neural
Positive	٤٣	٣	٤
Negative	٠	٠	٠
Neural	٠	٠	٠
	Positive	Negative	Neural

يوضح الجدول ٧- أن المصنف قام بتصنيف ٤ حالات دخل على أنها حيادية ولكنها في الحقيقة كانت إيجابية (حالة تصنيف خاطئ)، أيضاً قام المصنف بتصنيف ٣ حالات على أنها سلبية وكانت إيجابية (حالة تصنيف خاطئ)، بينما قام بتصنيف ٤٣ حالة على أنها إيجابية وبالفعل كانت كذلك (حالة تصنيف صحيح)، وبالتالي يمكن القول أن المصنف القديم أخطئ ٧ مرات من أصل ٥٠ مرة وأصاب ٤٣ مرة من أصل ٥٠ أي أن نسبة الخطأ هي $7/50=0.14$ أي نسبة الخطأ في المصنف القديم هي ١٤%.

	Positive	Negative	Neural
Positive	٤٧	٢	١
Negative	٠	٠	٠
Neural	٠	٠	٠
	Positive	Negative	Neural

يوضح الجدول ٨- أن المصنف قام بتصنيف حالة دخل واحدة على أنها حيادية ولكنها في الحقيقة كانت

إيجابية (حالة تصنيف خاطئ)، أيضاً قام المصنف بتصنيف حالتين على أنهما سلبيتان وكانتا إيجابيتان (حالة تصنيف خاطئ)، بينما قام بتصنيف ٤٣ حالة على أنها إيجابية وبالفعل كانت كذلك (حالة تصنيف صحيح)، وبالتالي يمكن القول أن المصنف الجديد أخطئ ٣ مرات من أصل ٥٠ مرة وأصاب ٤٧ مرة من أصل ٥٠ أي أن نسبة الخطأ هي $3/50=0.06$ %6.

عن طريق المقارنة بي الجدولين -٧- و -٨- يمكن ملاحظة تحسن الأداء في التصنيف بين النهجين والسبب طبعاً يعود في هذا التحسن إلى وجود المعجم الديناميكي واستخدام الرموز التعبيري في عملية التصنيف.

إيجابي	٠	٠	٠
سلبي	٤	٣٦	١٠
حيادي	٠	٠	٠
	إيجابي	سلبي	حيادي

يوضح الجدول -٩- أن المصنف قام بتصنيف ١٠ حالات دخل على أنها حيادية ولكنها في الحقيقة كانت سلبية (حالة تصنيف خاطئ)، أيضاً قام المصنف بتصنيف ٤ حالات على أنها إيجابية وكانت سلبية (حالة تصنيف خاطئ)، بينما قام بتصنيف ٣٦ حالة على أنها سلبية وبالفعل كانت كذلك (حالة تصنيف صحيح)، وبالتالي يمكن القول أن المصنف القديم أخطئ ١٤ مرة من أصل ٥٠ وأصاب ٣٦ مرة من أصل ٥٠ أي أن نسبة الخطأ هي $14/50=0.28$ %28.

إيجابي	٠	٠	٠
سلبي	٠	٤٤	٦
حيادي	٠	٠	٠
	إيجابي	سلبي	حيادي

يوضح الجدول -١٠- أن المصنف قام بتصنيف ٦ حالات دخل على أنها حيادية ولكنها في الحقيقة كانت سلبية (حالة تصنيف خاطئ)، أيضاً قام المصنف بتصنيف ٠ حالة على أنها إيجابية (لا يوجد حالة تصنيف خاطئ)، بينما قام بتصنيف ٤٤ حالة على أنها سلبية وبالفعل كانت كذلك (حالة تصنيف صحيح)، وبالتالي يمكن القول أن المصنف الجديد أخطئ ٦ مرات من أصل ٥٠ وأصاب ٤٤ مرة من أصل ٥٠ أي أن نسبة الخطأ هي $6/50=0.12$ %12.

عن طريق المقارنة بي الجدولين -٩- و -١٠- يمكن ملاحظة تحسن الأداء في التصنيف بين النهجين والسبب طبعاً يعود في هذا التحسن إلى وجود المعجم الديناميكي القابل على اكتساب معرفة جديدة بشكل مستمر حتى أثناء عملية تصنيفه للجمل واستخدام الرموز التعبيري في عملية التصنيف.

إيجابي	18	2	4
سلبي	2	22	1
حيادي	٠	1	25
	إيجابي	سلبي	حيادي

الجدول -١٢- مصفوفة الارتياب لعينة البيانات الثالثة عند تطبيقها على النهج الجديد			
إيجابي	20	1	1
سلبي	0	23	1
حيادي	٠	1	28
	إيجابي	سلبي	حيادي

٥- الاستنتاجات والتوصيات:

١-٥ الاستنتاجات:

إنّ اكتشاف وتحليل آراء المستخدمين ضمن شبكات التواصل الاجتماعي أصبح لأمر هام جداً وخصوصاً مع انتشارها في الفترة الأخيرة لذلك كان لابد من وجود طريقة حديثة تمكن من تصنيف آراء المستخدمين على وسائل التواصل الاجتماعي وباللغة العربية واللهجة العامية.

قامت هذه الدراسة بتسليط الضوء على بعض أهم طرائق الاكتشاف الحديثة والتي تعتمد على التعلّم المعزز لما قدّمه من نتائج مشجّعة في العديد من الدراسات السابقة ضمن هذا المجال وذلك على مجموعة بيانات عربية مأخوذة من التويتير وباستخدام خوارزمية التعلّم المعزز.

حيث اختبرت هذه الدراسة كفاءة النموذج في تصنيف سلوك المستخدمين ضمن البيانات العربية. كما قامت بإجراء مقارنة بين النهج القديم (تدريب معجم رأي للكلمات) والنهج الحديث المطبق (معجم قائم على التعلّم المعزز) بدراستنا وذلك من خلال قدرة كل نهج على تصنيف مجموعة من البيانات على أنها إيجابية أو سلبية أو حيادية، كما تمّ إجراء مقارنة من خلال الزمن الذي يستغرقه كل نهج في عملية التصنيف.

تبين النتائج التي عرضناها سابقاً على شكل مصفوفات ارتباط تحسن كبير لنهج المعجم الديناميكي الذي يوظف الرموز التعبيرية بالمقارنة مع النهج القديم القائم على معجم ستاتيكي ثابت والذي يعمل على حذف الرموز التعبيرية باعتبارها ضجيج يتم حذفه في مرحلة المعالجة المسبقة للبيانات وهذا الأمر تم نفيه في عملنا حيث أكدنا على أهمية الرمز التعبيري ووضحنا أثره بشكل واضح في سياق الدراسة.

٢-٥ التوصيات:

بناءً على النتائج السابقة يمكن تقديم عدد من التوصيات ومنها:

- استخدام مجموعات بيانات أكبر ومن شبكات تواصل اجتماعي متعددة ما يسمح بدراسة طيف أكبر من الكلمات وتحليلها وتقوية المعجم وخصوصاً مع استخدام اللهجة العامية.
- دراسة خطوات معالجة مسبقة مختلفة على البيانات لمعرفة مدى تأثيرها وتحديداً في اللغة العربية
- استخدام ميزات أخرى في التدريب، ودراسة تأثير استخراج الميزات على مستوى المحارف والجمل بدلاً من الكلمات فقط ومحاولة دمجها لمعرفة فيما إذا تحسّن من التصنيف أم لا.
- دراسة نماذج من شبكات عصبونية عميقة بدلاً من التعلّم المعزز مثل LSTM و RNN و GRU ودراسة المصنّفات في كل منها لإيجاد الأفضل ومحاولة ربط خرج بعض الشبكات إلى دخل شبكاتٍ من نوعٍ مختلفٍ لدراسة الأثر المضاعف لشبكتين أو أكثر في عملية التصنيف.

٦ - المراجع:

- [1] Akel, N. (2020). Analyzing University Students' Attitudes Through Social Media. *ASEAN Journal of Empowering Community*, 2(1), 19–28.
- [2] Alzahrani, L., & Department of Management Information Systems, College of Business Administration, Taif University, Saudi Arabia. (2023). Analyzing students' attitudes and behavior toward artificial intelligence technologies in higher education. *International Journal of Recent Technology and Engineering (IJRTE)*, 11(6), 65–73. <https://doi.org/10.35940/ijrte.f7475.0311623>
- [3] Amresh, A. (2023). Integrating reinforcement AI into the design of educational games. *Proceedings of the ... European Conference on Games-Based Learning*, 17(1), 13–18. <https://doi.org/10.34190/ecgbl.17.1.1709>
- [4] Chai, J., Zhu, Y., & Zhao, D. (2023). NVIF: Neighboring variational information flow for cooperative large-scale multiagent reinforcement learning. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/TNNLS.2023.3309608>
- [5] Chen, J., Lan, T., & Aggarwal, V. (2023). Hierarchical adversarial inverse reinforcement learning. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/TNNLS.2023.3305983>
- [6] Costa, E., Papatsouma, I., & Markos, A. (2023). Benchmarking distance-based partitioning methods for mixed-type data. *Advances in Data Analysis and Classification*, 17(3), 701–724. <https://doi.org/10.1007/s11634-022-00521-7>
- [7] Kim, S.-Y., Park, H., Jung, M., & Kim, K. K. (2020). Impact of body size match to an avatar on the body ownership illusion and user's subjective experience. *Cyberpsychology, Behavior and Social Networking*, 23(4), 234–241. <https://doi.org/10.1089/cyber.2019.0136>
- [8] Lamontagne, C., Sénécal, S., Fredette, M., Labonté-LeMoine, É., & Léger, P.-M. (2021). The effect of the segmentation of video tutorials on User's training experience and performance. *Computers in Human Behavior Reports*, 3(100071), 100071. <https://doi.org/10.1016/j.chbr.2021.100071>
- [9] Liew, J. W., King, L. K., Mahmoudian, A., Wang, Q., Atkinson, H. F., Flynn, D. B., Appleton, C. T., Englund, M., Haugen, I. K., Lohmander, L. S., Runhaar, J., Neogi, T., Hawker, G., & OARSI Early Osteoarthritis Classification Criteria Task Force. (2023). A scoping review of how early-stage knee osteoarthritis has been defined. *Osteoarthritis and Cartilage*, 31(9), 1234–1241. <https://doi.org/10.1016/j.joca.2023.04.015>
- [10] Lv, Y., Na, J., Zhao, X., Huang, Y., & Ren, X. (2023). Multi- H_{∞} controls for unknown input-interference nonlinear system with reinforcement learning. *IEEE Transactions on Neural Networks and Learning Systems*, 34(9), 5601–5613. <https://doi.org/10.1109/TNNLS.2021.3130092>
- [11] Meng, Y., Shi, F., Tang, L., & Sun, D. (2023). Improvement of reinforcement learning with supermodularity. *IEEE Transactions on Neural Networks and Learning Systems*, 34(9), 5298–5309. <https://doi.org/10.1109/TNNLS.2023.3244024>
- [12] Nakano, H., Ariizumi, R., Asai, T., & Azuma, S.-I. (2023). Automatic temperature parameter tuning for reinforcement learning using path integral policy improvement. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/TNNLS.2023.3312857>
- [13] Naresh, K. N., Medeiros, L. J., & WHO 5th Edition Classification Project. (2023). Introduction to the 5th edition of the world health organization classification of tumors of the hematopoietic and lymphoid tissues. *Modern Pathology: An Official Journal of the United States and Canadian Academy of Pathology, Inc*, 100330. <https://doi.org/10.1016/j.modpat.2023.100330>
- [14] Santosa, I., & Darodjatun, G. (2021). Socialization of da'wah through technology media information with the theme of understanding Muslim attitudes facing the covid-19 pandemic disaster. *ASEAN Journal of Empowering Community*, 2(1), 19–28. <https://doi.org/10.24905/ajecom.v2i1.3>
- [15] Sharp, A., Chalator, G., & Browne, R. P. (2023). A dual subspace parsimonious mixture of matrix normal distributions. *Advances in Data Analysis and Classification*, 17(3), 801–822. <https://doi.org/10.1007/s11634-022-00526-2>

[16] Shin, Y., & Kim, J. (2018). Data-centered persuasion: Nudging user's prosocial behavior and designing social innovation. *Computers in Human Behavior*, 80, 168–178. <https://doi.org/10.1016/j.chb.2017.11.009>

[17] Vimalkumar, M., Sharma, S. K., Singh, J. B., & Dwivedi, Y. K. (2021). 'Okay google, what about my privacy?': User's privacy perceptions and acceptance of voice based digital assistants. *Computers in Human Behavior*, 120(106763), 106763. <https://doi.org/10.1016/j.chb.2021.106763>

[18] Wang, Q., & Xue, Y. (2023). A structured covariance ensemble for sufficient dimension reduction. *Advances in Data Analysis and Classification*, 17(3), 777–800. <https://doi.org/10.1007/s11634-022-00524-4>

[19] Wang, R., Wang, G., Sun, J., Deng, F., & Chen, J. (2023). Flexible job shop scheduling via dual attention network-based reinforcement learning. *IEEE Transactions on Neural Networks and Learning Systems*, PP, 1–12. <https://doi.org/10.1109/TNNLS.2023.3306421>

[20] Wang, Y., Cao, J., Sun, J., Zou, X., & Sun, C. (2023). Path following control for unmanned surface vehicles: A reinforcement learning-based method with experimental validation. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/TNNLS.2023.3313312>

[21] Zhao, H., Shan, J., Peng, L., & Yu, H. (2023). Adaptive event-triggered bipartite formation for multiagent systems via reinforcement learning. *IEEE Transactions on Neural Networks and Learning Systems*, PP. <https://doi.org/10.1109/TNNLS.2023.3309326>

[22] Zhao, L., Zuo, Y., & Yada, K. (2023). Sequential classification of customer behavior based on sequence-to-sequence learning with gated-attention neural networks. *Advances in Data Analysis and Classification*, 17(3), 549–581. <https://doi.org/10.1007/s11634-022-00517-3>