

التنبؤ بحالات الاختناق في الشبكات المعرفة برمجياً بالاعتماد على تقنيات التعلم العميق

د.م. محمد عنبر*

م. حلا مرجان**

(تاريخ الإيداع 2022/ 2/15 . قَبْلُ للنشر في 2022/6/14)

□ ملخص □

الشبكات المعرفة برمجياً (SDN) Software-Defined Networks هي منهج أو أسلوب جديد في إدارة شبكات الحاسب، حيث يستطيع مسؤول الشبكة إدارة الشبكة بطريقة مجردة بعيداً عن معرفة تفاصيل الشبكة في الطبقات الدنيا، وتعتبر عن قدرة التطبيقات على برمجة أجهزة الشبكة الفردية ديناميكياً وبالتالي التحكم في سلوك الشبكة ككل. يعد التنبؤ بالاختناقات مهماً لتحليل الأداء وتخطيط الشبكات المعرفة برمجياً (SDN). تم في هذا البحث مناقشة أداء شبكة افتراضية معروفة البنية مسبقاً بنطاق ترددي ثابت ويوجد متحكم SDN من نوع POX. تم تنفيذ سلسلة من التراسلات لمدة عشر دقائق بين مستخدمين ضمن الشبكة وتم تحقيق حالة من الازدحام. تم في النهاية استخلاص بعض السمات المميزة والخصائص التي تم استخدامها كبيانات دخل لشبكة عصبونية من نوع (LSTM) Long Short-Term Memory. تظهر النتائج أنه بالاعتماد على استيفاء نسبة معدل تغير (معدل التراسل، البيانات المستلمة، عرض الحزمة المستخدم) من خلال تنسيبها الى حالة مرجعية مثالية أو حالة سابقة، يمكن توفير بيانات دخل معالجة مسبقاً وسهلة التحليل بالنسبة لشبكات LSTM. تظهر النتائج قدرة LSTM على إعطاء السلوك التقريبي لتغير أداء الشبكة من معدل انحراف القيم وبعدها عن الحالة الأولية، بالإضافة الى إعطاء توقع عددي تقريبي لنسبة معدل التراسل وعرض الحزمة.

الكلمات المفتاحية: الشبكات المعرفة برمجياً - موازنة الأحمال - الشبكات العصبونية.

* مدرس - كلية تكنولوجيا المعلومات والاتصالات - جامعة طرطوس - سورية.

** طالبة دراسات عليا (ماجستير) - كلية تكنولوجيا المعلومات والاتصالات - جامعة طرطوس - سورية..

Predicting traffic in SDNs based on deep learning techniques

Dr. Mohammad Anbar*

Eng. Hala Morgan**

(Received 15/2/ 2022 . Accepted 14 /6/ 2022)

□ ABSTRACT □

Software-defined networks (SDN) is a new approach or method for managing computer networks, in which the network administrator can manage the network in an easy way without involving in the details of the network at the lower layers, and expresses the ability of applications to dynamically controlling individual network devices. Traffic forecasting is important for performance analysis and monitoring of SDN. In this paper, the performance of a SDN network with fixed bandwidth and a POX-type SDN controller is discussed. A series of data over ten minutes was carried out between two users within the network and a traffic case was achieved. Finally, some features and characteristics are extracted and used as input data for a long short-term memory (LSTM) neural network. The results show that depending on the interpolation of the rate-of-change ratio (transfer rate, received data, used bandwidth) by assigning it to an ideal reference state or a previous state, it is possible to provide pre-processed and easy-to-analyze input data for LSTM networks. The results show the ability of LSTM to give the approximate behavior of the network performance based on the deviation rate of the values and their distance from the initial state, in addition to giving an approximate numerical prediction of the transfer rate and bandwidth ratio.

Keywords: Software-defined networks - load balancing – Neural networks.

* Lecturer, Faculty of Information and Communication Technology - Tartous University - Syria.

** M.Sc. student, Faculty of Information and Communication Technology - Tartous University - Syria.

1. مقدمة

مع توسع الشبكات وزيادة مستخدميها فضلاً عن التقنيات الجديدة الناشئة مثل الحوسبة السحابية cloud computing والبيانات الضخمة big data، أصبحت إدارة الشبكات التقليدية أمراً صعباً. لذلك أصبح من الضروري تغيير بنية الشبكة التقليدية. في الآونة الأخيرة ولمعالجة هذه المشكلة تم اقتراح مفهوم يسمى الشبكة المعرفة برمجياً (SDN) Software-Defined Network، مما يجعل إدارة الشبكة أكثر توافقاً وتلاءماً من قبل الاختصاصيين. نظراً لموارد الشبكة المحدودة ولتلبية متطلبات جودة الخدمة، فإن إحدى النقاط التي يجب مراعاتها هي مشكلة موازنة الحمل/الأحمال (LB) Load Balancing التي تعمل على توزيع حركة مرور البيانات بين موارد متعددة من أجل زيادة كفاءة موارد الشبكة وموثوقيتها. يتم إنشاء موازنة الحمل بناءً على المعلومات المحلية للشبكة في الشبكة التقليدية Conventional Network وبالتالي فهي ليست دقيقة للغاية. ومع ذلك فإن وحدات تحكم SDN لديها رؤية شاملة للشبكة ويمكنها إنتاج أحمال موزعة بشكل مثالي Optimized Load Balances [1].

موازنة الأحمال هي تقنية لتقسيم عبء العمل أو الأحمال على موارد متعددة لتجنب الحمل الزائد على أي من الموارد. يعتبر كلاً من زيادة الإنتاجية maximizing throughput وتقليل وقت الاستجابة minimizing response time وأمثلة حركة المرور optimizing traffic من بعض أهداف موازنة الحمل. الشبكات التقليدية ليس لديها رؤية شاملة للشبكة، لذلك فإن طرق موازنة الحمل في الشبكات التقليدية ليست دقيقة. لكن طرق موازنة الحمل في SDN أكثر دقة ولها أداء أعلى. في الأبحاث المرتبطة بـ SDN تعد مسألة موازنة الحمل واحدة من أهم القضايا بسبب مخاوف الصناعة Industry Concerns [2].

بشكل أساسي لتحسين الأداء الكلي للعتاد المادي والبرمجي في الأنظمة الموزعة distributed systems، يتم استخدام تقنية موازنة الحمل. يمكن تنفيذ موازنة الحمل باستخدام جهاز (عتاد مادي) به نظام تشغيل متخصص يوزع حركة البيانات والتراسل عبر مجموعة من الخوادم، حيث يوزع موازن الحمل ويعالج الازدحام وفقاً لقواعد مخصصة حتى لا تتعرض الخوادم للاختناق وهي مسؤولة عن توزيع الحمل بين عدة موارد من نفس النوع. موازنة الحمل لها عدة طرق ومبادئ، حيث يمكن أن تكون هذه الطرق ثابتة static أو ديناميكية dynamic أو مختلطة. في الطرق الثابتة يعد الحصول على معلومات مسبقة عن النظام ميزة أساسية، حيث تتم برمجة القاعدة أو الطريقة مباشرة في موازن الحمل load balancer ويتم تنفيذها دون تعديل، ولكن نظراً لأنه لا يمكن التنبؤ بسلوك المستخدم، يمكن أن تكون طرق موازنة الحمل الثابتة غير كافية في الشبكة. تعتبر الطرق الديناميكية أكثر فاعلية من الطرق الثابتة لأن الحمل يتم توزيعه ديناميكياً وفقاً لبعض الأنماط المبرمجة مسبقاً في موازن التحميل. تساعد طريقة موازنة الحمل المناسبة على تقليل وقت الاستجابة، زيادة الإنتاجية، تقليل استهلاك الموارد، وتجنب التحميل الزائد لأي مورد فردي [3].

هناك نوعان رئيسيان من موازنة الحمل: موازنة الحمل في شبكة IP وفي شبكة SDN. في الشبكة التقليدية القائمة على بروتوكول الإنترنت (IP) تتم موازنة الحمل من خلال جهاز توجيه موازنة التحميل Load Balancing (LBR) Router، وإذا دخل تدفق جديد إلى الشبكة فسوف يمر مبدئياً عبر LBR. في شبكة SDN لتحقيق موازنة الحمل المطلوبة يجب على وحدة التحكم إكمال سلسلة من تحديدات الخادم الأقل تحميلاً في الوقت الفعلي Realtime Least loaded Server selections (RLS). لتحديد المخدم الهدف target server لتدفق جديد يتم تطبيق RLS ويستخدم أيضاً لحساب المسار المؤدي إلى الخادم الهدف بينما يدخل التدفق الجديد في النطاق domain للمرة الأولى استناداً إلى حالة الشبكة في الوقت الفعلي، يتخذ RLS قرار إعادة التوجيه لكل تدفق جديد.

1.1. الدراسات المرجعية

قدم الباحث **Yang** وزملاءه عام (2019) تقنية موازنة أحمال تنبؤية ضمن شبكات SDN السحابية، التقنية تضمنت استخدام قناع محرف البديل Wildcard mask لتنفيذ طريقة موازنة التحميل مباشرة على المبدلات أو أجهزة التوجيه وإضافة آلية تنبؤ للمستخدم لتغيير نطاق قناع wildcard ديناميكياً. بهذه الطريقة يمكن تطبيق آلية موازنة الحمل بما يتوافق مع مواقف الخدمة الحقيقية. الباحثون قاموا باختبار دقة التنبؤ بالتدفق لخوارزميات متوقعة مختلفة ومقارنة أوقات التأخير وحالات التوازن للطريقة المقترحة مع موازنات الأحمال الأخرى. وأثبتوا أيضاً فعالية طريقتهم في موازنة التحميل على الخدمات السحابية وإمكانية تنفيذها على أنواع مختلفة من منصات الخدمة [4].

عمل **Xu** وزملاءه عام (2019) على تنفيذ متحكم بتوزيع الأحمال من خلال التبديل الديناميكي لانتقال البيانات داخل شبكات SDN الموزعة، حيث أظهروا أن التعيين (التخطيط) الديناميكي dynamic mapping بين المبدلات وأجهزة التحكم يمكن أن يحسن الكفاءة في إدارة اختلاف ازدحامات الأحمال. حيث اقترحوا وحدة تحكم متوازنة (Balanced Controller (BalCon) و BalConPlus ومخططا SDN تبديل الهجرة لتحقيق توازن الحمل بين وحدات تحكم SDN بتكلفة ترحيل صغيرة. يعد BalCon مناسباً للسيناريوهات التي لا تتطلب فيها الشبكة معالجة تسلسلية لطلبات التبديل. بالنسبة للسيناريوهات الأخرى والتي تسمى السيناريوهات الديناميكية التي تعتمد على بنية شبكة مختلفة وعلى توليد تدفق البيانات المرسل والمستقبل عند العقد الطرفية بعد عملية Poisson، يعتبر BalConPlus أكثر ملاءمة، لأنه محصن ضد تعتيم ترحيل التبديل ولا يسبب أي انقطاع في الخدمة. توضح عمليات المحاكاة أن BalCon و BalConPlus يقللان بشكل كبير من اختلال توازن الحمل بين وحدات تحكم SDN من خلال ترحيل عدد صغير فقط من المفاتيح ذات الحمل المنخفض للحساب. التجربة تؤكد نتائج عمليات المحاكاة. كما يظهر أن BalConPlus محصن من تعتيم تبديل الهجرة، وهو تأثير سلبي في خط الأساس BalCon [5].

ضمن شبكات SDN يتم جمع كمية كبيرة من البيانات إلى السحابة لتحليلها، مما يؤدي إلى زيادة كمية بيانات ووقت استجابة أطول للخدمة. لذلك قدم الباحث **Liu** وزملاءه عام (2020) طريقة جديدة في موازنة الأحمال وتسريع الاستجابة ضمن الشبكات السحابية المعتمدة على شبكات SDN. حيث تم اقتراح بيئة عمل جديدة لتنسيق الخدمة وتجميع البيانات Service Orchestration and Data Aggregation (SODA) framework ، والذي يمكنها تنسيق البيانات كخدمات وتجميع حزم البيانات لتقليل تكرار البيانات وتأخير استجابة الخدمة. في SODA تنقسم الشبكة إلى ثلاث طبقات:

(1) طبقة مراكز البيانات (Data Centers Layer (DCL): المسؤولة عن إدارة برامج ذات وظيفة محددة لجميع الأجهزة في الشبكة.

(2) طبقة التوجيه الوسطى (Middle Routing Layer (MRL): يتم ضبط مسار توجيه حزم البيانات في هذه الطبقة وفقاً لارتباط حزم البيانات ومسافة التوجيه. يكون ارتباط حزم البيانات أعلى ومسافة التوجيه قصيرة، واحتمال إرسال حزم البيانات على طول مسار التوجيه نفسه يكون أعلى لتقليل البيانات المتكررة.

3) طبقة شبكة المركبات (VNL) Vehicle Network Layer: تُستخدم المركبات المتحركة لنقل حزم البيانات والخدمات بين الأجهزة. تم إجراء سلسلة من التجارب والمحاكاة، وتوضح النتائج أن المخطط المقترح له أداء أفضل مقارنة بالنظام التقليدي [6].

مؤخراً بدأ الباحثون بالعمل على إدخال تقنيات الذكاء الاصطناعي وتعلم الآلة ضمن بنية الشبكة البرمجية من أجل تحسين خوارزميات موازنة الأحمال. حيث استخدم **Begam** وزملاءه عام (2021) خوارزمية بحث متعددة قائمة على الانحدار (MRBS) Multiple Regression-Based Searching لاختيار الخادم الأمثل ومسار التوجيه في شبكات SDN لتحسين الأداء حتى في ظل ظروف الأحمال الكبيرة وحالات الاختناق مثل ارتفاع معدل الرسائل وتكرار الرسائل المختلفة وأنماط المرور غير المتوقعة. حيث قلصت الخوارزمية المقترحة التأخير والوقت إلى أكثر من 45%. وتُظهر استخداماً أفضل للخادم بنسبة 83% عند مقارنتها بالخوارزميات التقليدية [7].

في حين استخدم **Babayigit** و **Ulu** عام (2021) تقنية التعلم العميق (DL) deep learning لموازنة الحمل في شبكات SDN. حيث تم تدريب نموذج التعلم العميق المشابه للشبكة العصبونية التقليدية على قيم الحمل المتغير بين الروابط. وتمت مقارنة وقت الاستجابة لموازنة الحمل لتقنية DL مع الشبكة العصبونية الاصطناعية (ANN) Artificial Neural Network و Support Vector Machine (SVM) والانحدار اللوجستي (LR) Logistic Regression. كشفت النتائج التجريبية أن نتائج وقت الاستجابة لـ ANN و DL أقل من نتائج خوارزميات SVM و LR ، كما أن دقة DL أعلى من دقة ANN [8].

استخدم **Naing** وزملاءه عام (2020) التعلم المعزز (RL) Reinforcement Learning لتحسين اختيار المبدلات ووحدة التحكم فيما يخص switch migration، باستخدام منهجية موازنة الحمل المعزز بالتعلم والمدرّك للتبديل (SAR-LB) Switch-Aware Reinforcement Learning Load Balancing. يتعامل SAR-LB مع معدل استخدام أنواع الموارد المختلفة في كل من وحدات التحكم والمبدلات كمدخلات للشبكة العصبونية وتم اعتبار المبدلات بمثابة عوامل RL لتقليل مساحة العمل للتعلم، بينما تأخذ في الاعتبار جميع حالات الترحيل. أظهرت النتائج التجريبية أن SAR-LB حققت توزيعاً أفضل (قريب من التوزيع المتساوي) للحمل بين وحدات تحكم SDN بسبب اتخاذ القرار الدقيق لترحيل التبديل [9].

من خلال ما تم مراجعته من أبحاث نلاحظ اهتمامها بمجال تحسين كفاءة موازنة الأحمال ضمن الشبكات المعرفة برمجياً و الحد من الاختناقات من خلال دمج تقنيات موازنة الأحمال مع الذكاء الاصطناعي. يأتي هذا البحث للتركيز على استخدام الذكاء الاصطناعي في التنبؤ بالاختناقات بحيث يمكن توفير تدخل سريع لاختصاصي الشبكات لحل المشكلة في الوقت المناسب، وفي البحث الحالي سيتم العمل على استخلاص السمات التي تفيد في التنبؤ ليتم استخدامها كمدخل للشبكة العصبونية (LSTM) Long Short-Term Memory.

2.1. مشكلة البحث

تحافظ خوارزميات موازنة الأحمال LB الديناميكية على استمرار التعديلات على عبء عمل النظام وتعيد توزيع الحمل وفقاً لذلك، وبالتالي يجب أن تكون خوارزمية LB الديناميكية قادرة على: (1) تحديد المهمة المناسبة لنقلها إلى خادم آخر (2) تحديد موقع الخادم المناسب لتنفيذ المهمة المنقولة (3) تحديد معلومات LB المطلوبة. LB الديناميكي أكثر كفاءة من LB الساتاتيكي حيث يتم اتخاذ القرار في الوقت الفعلي. ومع ذلك قد يتسبب Dynamic LB في حدوث اختناق في الشبكة.

السؤال الرئيسي الذي يطرحه البحث، كيف يمكن استخدام تقنيات تعلم الآلة والذكاء الاصطناعي للتنبؤ بالاختناقات على مستوى الخدمات بالاستفادة من تقنيات موازنة الأحمال المعروفة في شبكات SDN؟ وكيفية العمل على استخلاص سمات وخصائص محددة يمكن استخدامها بشكل فعال مع تقنيات الذكاء الاصطناعي الملائمة؟

3.1. أهمية البحث

من خلال الاطلاع على الأبحاث السابقة والخوارزميات والتقنيات المتوفرة لحل مشكل الاختناقات والأحمال غير المنتظمة، يقترح البحث طريقة حول استيفاء بعض السمات والبارامترات المميزة التي يمكن استخدامها مع تقنيات تعلم الآلة للتنبؤ بهذه المشكلة أو القدرة على التعامل معها بشكل آني وموثوق، سواء بالتدريب المسبق على سيناريوهات سابقة أو بالاعتماد على خبرة مهندس الشبكات في وضع قواعد تتيح لخوارزمية تعلم الآلة المعتمدة توزيع الأحمال بالشكل الأمثل.

2. الشبكات المعرفة برمجياً وموازنة الأحمال

الشبكات المعرفة برمجياً مصطلح من نموذج الشبكات القابلة للبرمجة. باختصار يشير SDN إلى قدرة تطبيقات البرامج على برمجة أجهزة الشبكة الفردية ديناميكياً وبالتالي التحكم في سلوك الشبكة ككل. وتعرف أيضاً SDN على أنها عبارة عن مجموعة من التقنيات المستخدمة لتسهيل تصميم خدمات الشبكة وتسليمها وتشغيلها بطريقة موثوقة وديناميكية وقابلة للتطوير [10,11].

أحد المبادئ الأساسية في SDN هو النقل من التعقيد بين مستويات إعادة التوجيه (التقليدية) والتحكم من أجل فصلها وتزويد التطبيقات بالوسائل اللازمة للتحكم في الشبكة برمجياً. الهدف الأساسي من هذا الفصل هو قابلية البرمجة وتمكين الابتكار الأسرع في كلا المستويين.

تتكون بنية الشبكات المعرفة برمجياً من 3 طبقات:

1. طبقة التطبيق application layer: تحتوي طبقة التطبيق على برامج تنقل بشكل

صريح وبرمجي سلوك الشبكة المطلوب ومتطلبات الشبكة إلى وحدة تحكم SDN وهي منطقة مفتوحة لتطوير أكبر قدر ممكن من التطبيقات المبتكرة من خلال الاستفادة من جميع معلومات الشبكة حول طوبولوجيا الشبكة وحالة الشبكة وإحصاءات الشبكة. يمكن أن يكون هناك عدة أنواع من التطبيقات التي يمكن تطويرها مثل تلك المتعلقة بأتمتة الشبكة وتكوين الشبكة والإدارة ومراقبة الشبكة واستكشاف أخطاء الشبكة وسياسات الشبكة وأمانها.

2. طبقة تحكم control layer: وحدة تحكم SDN هي الطبقة الوسطى التي تربط

طبقة التطبيق وطبقة البنية التحتية. تعالج هذه الطبقة التعليمات والمتطلبات التي ترسلها طبقة التطبيق وتنتقل بها إلى مكونات الشبكة (عبر الواجهة الشمالية). كما يقوم أيضاً بتوصيل المعلومات الضرورية المستخرجة من أجهزة الشبكات إلى التطبيق حتى يعمل على النحو الأمثل. نظراً لأن وحدة تحكم SDN مخصصة لإدارة الشبكات، لذلك يجب أن يكون لها منطق تحكم لحالات استخدام الشبكة في العالم الحقيقي مثل التبديل والتوجيه و L2 VPN و L3 VPN وقواعد أمان جدار الحماية و DNS و DHCP والتجميع.

3. **طبقة البنية التحتية infrastructure layer**: تتكون من أجهزة الشبكات التي تتحكم في إعادة التوجيه ومعالجة البيانات للشبكة. تمثل الأجهزة المسؤولة عن التعامل مع الحزم بناءً على القواعد التي توفرها وحدة التحكم. وهي الطبقة المادية المسؤولة عن جمع حالات الشبكة مثل إحصاءات حركة المرور وطوبولوجيا الشبكة واستخدام الشبكة وإرسالها إلى طبقة التحكم. هذه الطبقة هي الطبقة المادية التي يتم من خلالها وضع المحاكاة الافتراضية للشبكة من خلال طبقة التحكم (حيث توجد وحدات تحكم SDN وتدير الشبكة المادية الأساسية).

تتميز شبكات SDN بما يلي:

1. **قابل للبرمجة مباشرة directly programmable**: يمكن أن يكون التحكم في الشبكة قابلاً للبرمجة مباشرة حيث يتم فصله عن وظائف إعادة التوجيه.
 2. **تدار مركزياً centrally managed**: في وحدات تحكم SDN المستندة إلى البرامج يكون ذكاء الشبكة (منطقيًا) مركزيًا والذي يحافظ على رؤية شاملة للشبكة.
 3. **الرشاقة agile**: يتيح التحكم المجرّد من إعادة التوجيه للمسؤول إمكانية إدارة تدفق حركة المرور على مستوى الشبكة ديناميكيًا لتلبية الاحتياجات المتغيرة.
 4. **مهياًة برمجيًا programmatically configured**: في SDN يمكن لمديري الشبكة إدارة موارد الشبكة وتكوينها وتأمينها وتحسينها بسهولة وسرعة.
- يفصل موازن الحمل المستند إلى SDN فعلياً مستوى التحكم في الشبكة عن مستوى إعادة التوجيه. يمكن التحكم في أكثر من جهاز في نفس الوقت عند موازنة التحميل باستخدام SDN. تؤدي هذه النظرة العامة إلى موازنة تحميل أمثل [12].
- توفر الشبكات المعرفة برمجيًا (SDN) تحكماً مرناً حتى تتمكن المنظومات من الاستجابة لمتطلبات العمل المتغيرة بسرعة أكبر. تفصل موازنة التحميل في SDN مستوى التحكم الفعلي في الشبكة عن مستوى البيانات، حيث يسمح موازن التحميل المستند إلى SDN بالتحكم في أجهزة متعددة. هذه الطريقة التي يمكن أن تصبح بها الشبكات أكثر مرونة. يمكن برمجة التحكم في الشبكة مباشرة للحصول على خدمات تطبيق أكثر استجابة وكفاءة [13].

يعمل موازن التحميل المستند إلى SDN على توفير وقت التشغيل من خلال التحكم في شبكة كاملة من خوادم التطبيق والويب، وتؤدي موازنة التحميل في SDN إلى اكتشاف أفضل مسار وخدام لتسليم الطلبات بشكل أسرع.

تتضمن موازنة أحمال الشبكات المعرفة برمجيًا (SDN) الفوائد التالية [1]:

- تكلفة أقل
- قابلية تطوير أكبر
- موثوقية أعلى
- المرونة في التكوين
- تقليل وقت النشر
- أتمتة

3. طرق البحث ومواده

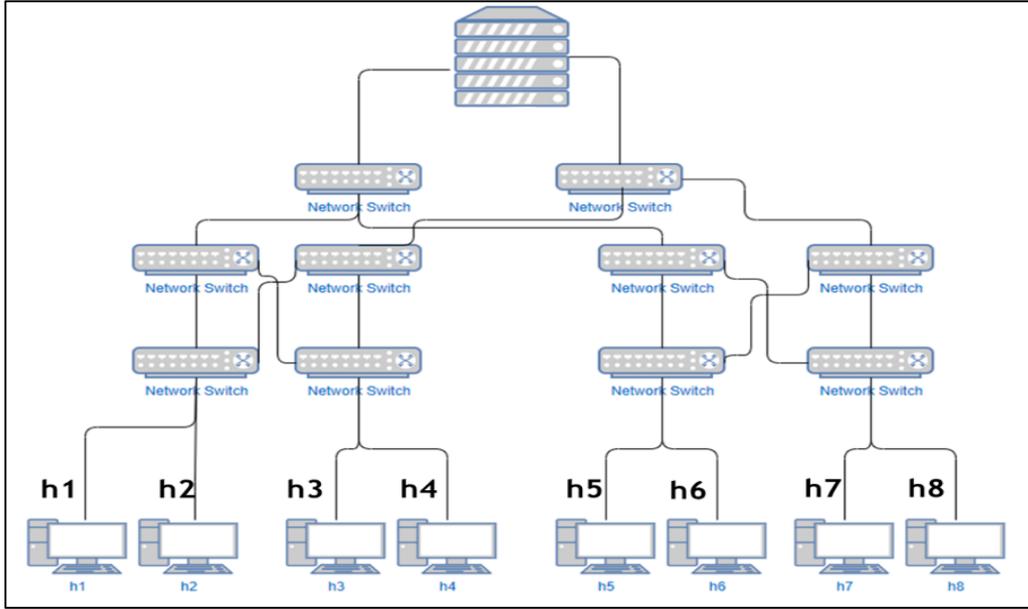
1.3. شبكة SDN وموازنة الأحمال

كما تمت المناقشة سابقاً إن مفهوم الازدحام في شبكات SDN وموازنة الأحمال له كثير من المعايير والبارامترات القابلة للقياس والتقييم من أجل معالجة مشكلة الاختناقات في الشبكات. في هذا البحث الهدف الرئيسي هو العمل على توفير سمات وبيانات يمكن استخدامها لاحقاً مع أدوات الذكاء الاصطناعي من أجل التنبؤ بالاختناقات أو العمل على حلها في الوقت المناسب. تم العمل في هذا البحث على استخراج السمات ذات التأثير الأكبر على سلوك الاختناقات بحيث تكون إشارات أحادية البعد قابلة للاستخدام من قبل تقنيات الذكاء الاصطناعي المختلفة. من أجل تحقيق هذا الهدف تمت محاكاة برمجية لشبكة SDN تحتوي عدد من المستخدمين hosts والمبدلات switches ولكن ضمن عدد محدود من العناصر (مستخدمين ومبدلات) بحيث يمكن مناقشة المنهجية المقترحة بسهولة وإمكانية إيضاح أسهل لطريقة استخدام تعلم الآلة في التنبؤ في مشكلة الاختناقات ضمن الشبكة المفترضة وفق الخطوات التالية والموضحة في الشكل (1):

1. إنشاء وتهيئة شبكة SDN تحتوي على 4 مخدمات، 4 مستخدمين و 10 مبدلات بينية حيث الوصلات تعمل بعرض حزمة 100 Mbps.
2. اعتبار الأجهزة h1 حتى h4 كمستخدمين و h5 حتى h8 كمخدمات كما هو موضح في الشكل (2).
3. استخدام طريقة Weighted Round Robin كطريقة موازنة أحمال.



الشكل(1): خطوات محاكاة برمجية لشبكة SDN ودراسة مخرجات سيناريوهات موازنة الحمل.



الشكل(2): بنية الشبكة المستخدمة في البحث ضمن بيئة Mininet والتي تحتوي على أربع مستخدمين وأربع مخدمات. تم استخدام Oracle VirtualBox التي تتيح استخدام نظام التشغيل Ubuntu Linux داخل نظام التشغيل Window. سيتم استخدام نظام تشغيل Ubuntu Linux جاهز يحتوي على منصة Floodlight OpenFlow Controller (Floodlight v1.2 Release) ومنصة Mininet (Mininet 2.3.0). من أجل تحقيق نظام محاكاة متكامل لشبكة SDN وتطبيق خوارزمية موازنة أحمال يجب العمل وفق الخطوات التالية:

- 1- استخدام بيئة mininet ضمن نظام التشغيل Ubuntu من أجل بناء شبكة افتراضية لنموذج شبكة SDN وفق متحكم floodlight الذي يعمل كوحدة تحكم افتراضية خاصة بشبكات SDN ويوفر العديد من الميزات عدد مستخدمين ومبدلات محدد مسبقاً.
- 2- لغة البرمجة Python من أجل تطبيق خوارزميات موازنة الأحمال واختبار سيناريوهات لعدد من المراسلات بين المستخدمين من أجل اختبار فعالية طريقة موازنة الاحمال المستخدمة. الأدوات البرمجية اللازمة للعمل هي على الشكل التالي:

1. Mininet

Mininet هو محاكي شبكة قائم على نظام التشغيل Linux، يمكن باستخدامه بناء شبكة برمجية افتراضية. يمكن استخدام Mininet لإنشاء شبكة افتراضية بسرعة تشغيل نواة فعلية في الأجهزة والمبدلات و APIs على جهاز كمبيوتر شخصي. تم في هذا البحث استخدام Mininet لبناء شبكة افتراضية مناسبة حسب تحليل النظام والذي يحاكي سيناريو حقيقي. باستخدام هذه الأداة يمكن إنشاء طوبولوجيا مخصصة باستخدام لغة Python حيث توفر Mininet إمكانية إنشاء شبكة من خلال عدد من الأصناف والتوابع المعرفة مسبقاً بلغة Python التي تتيح للمبرمج تحديد عدد المستخدمين والمبدلات البينية وتحديد IP الخاص بكل جهاز والكود البرمجي يتم تخزينه بملف منفصل ذو لاحقة ".py". ليتم تحديده لاحقاً أثناء تفعيل منصة Mininet.

2. POX controller

POX عبارة عن وحدة تحكم (SDN) / Software Defined Networking / OpenFlow مفتوحة المصدر تعتمد على Python. يتم استخدام POX للتطوير واختبار النماذج الأولية لتطبيقات الشبكة الجديدة

بشكل أسرع. ويعمل مع بروتوكول OpenFlow لتطوير بيئة SDN. حيث يعرف OpenFlow على أنه بروتوكول اتصال، من خلاله يتواصل مستوى التحكم (وحدة تحكم SDN) مع مستوى إعادة التوجيه (المحولات وأجهزة التوجيه).

تم استخدام وحدة التحكم في POX نظراً لتصميمها المعياري وسهولة استخدام واجهات REST APIs لتطوير التطبيقات.

3. Iperf

تم في هذا البحث استخدام Iperf لإنشاء تدفق بيانات من حزم ICMP لتحليل النطاق الترددي بين المضيفين (المستخدمين) المحددين وإنشاء حزم TCP أو UDP لقياس الإنتاجية والخسائر، وتسمح للمستخدم بتحسين أو اختبار الشبكة عن طريق تعيين بارامترات مختلفة مثل حجم البيانات. تحتوي مخرجات Iperf النموذجية على تقرير مؤثق بالوقت لكمية البيانات المنقولة والإنتاجية المقاسة.

4. Ping

يُظهر الاتصال بين مضيفين معينين من خلال إرسال عدة حزم افتراضية بينهم، ومخرجات هذه الاداة هي زمن الاستجابة (الزمن اللازم للإرسال والاستقبال)، عدد الحزم المستقبلية ونسبة الحزم المفقودة.

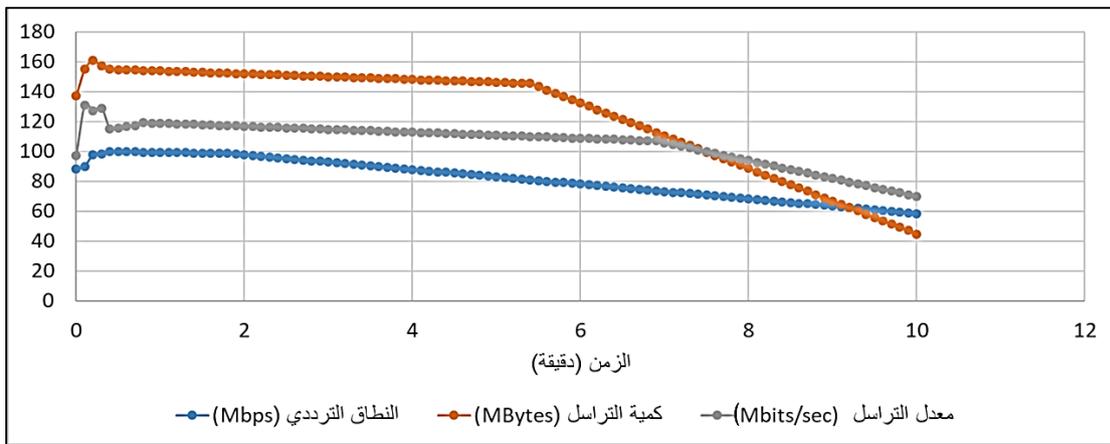
2.3. شبكة LSTM

شبكة ذات ذاكرة طويلة المدى (LSTM) هي نوع من الشبكات العصبونية المتكررة التي تستخدم سلسلة من الملاحظات للقيام بعملية تنبؤ للتسلسل الزمني للبيانات. LSTM هي منطقة معقدة من التعلم العميق حيث تم تصميم LSTMs بشكل صريح لتجنب مشكلة تبعية البيانات طويلة المدى وحفظ واسترداد المعلومات لفترات طويلة. جميع الشبكات العصبونية المتكررة لها شكل سلسلة من الوحدات المتكررة للشبكة العصبونية [14]. للتنبؤ بقيم الخطوات الزمنية المستقبلية لتسلسل البيانات يمكننا تدريب الانحدار من خلال الانتقال ضمن سلسلة البيانات حيث تكون الاستجابات هي تسلسلات التدريب مع تغيير القيم بخطوة لمرة واحدة. أي أنه في كل خطوة زمنية لتسلسل الإدخال تتعلم شبكة LSTM التنبؤ بقيمة الخطوة الزمنية التالية. أثناء تدريب الشبكة يتم حساب تدرج التكلفة باستخدام مجموعة معينة من الأوزان، وضبط الأوزان وفقاً لذلك وتكرر هذه العملية حتى يتم الحصول على أفضل مجموعة من الأوزان التي تعطي أقل تكلفة [15]. في قسم النتائج سيتم توضيح السمات أو الإشارات التي سيتم استخدامها مع LSTM للتنبؤ بسلوك الشبكة. سيتم إنشاء شبكة LSTM مع 200 وحدة مخفية hidden units، وخوارزمية الحل solver ضمن الشبكة هي 'adam' وعدد تكرارات epochs يساوي 250 وعتبة التدرج تساوي 1 ومعدل التعلم الأولي هو 0.005. تم تدريب الشبكة باستخدام 70% من تسلسل بيانات ليتم اختبار الشبكة بالتنبؤ بسلوك 30% المتبقية. تم تنفيذ LSTMs في هذه الورقة باستخدام Deep Learning Toolbox ضمن بيئة MATLAB (The MathWorks, Inc., 2019). يتم إجراء جميع العمليات الحسابية على كمبيوتر محمول يحتوي على وحدة المعالجة المركزية Intel (R) Core i5-4300U CPU @ 1.90 (TM) جيجاهرتز، ويتكون المعالج من نواتين، و 4 معالجات منطقية.

4. النتائج والمناقشة

1.4. نتائج محاكاة شبكة SDN وموازنة الأحمال

من خلال استخدام النوافذ الطرفية "xterm" ضمن mininet تم تنفيذ تبادل حزم بيانات بين المستخدمين h1 و h4 لمدة عشر دقائق. خلال عمليات التراسل تم حساب زمن التراسل (باستخدام ping) ومعدل التراسل (باستخدام iPerf) مع موازنة الأحمال كما هو موضح في الشكل (3). تظهر النتائج أنه خلال الدقيقة الخامسة بدأ المخدم بالتعامل مع التراسلات بأداء أقل. بالرغم من تفعيل أداة موازنة الأحمال Weighted Round Robin ضمن المتحكم POX ولكن نتيجة عدم قدرة المخدم المرتبطة بإمكانيات العتاد المادي على التعامل مع حزم البيانات، بدأت حالة الاختناق بالظهور من خلال انخفاض معدل التراسل وكمية البيانات المستقبلية في المستخدم h4.



الشكل (3): نتيجة تنفيذ التراسل بين المستخدمين h1 و h4 لمدة 10 دقائق.

2.4. السمات والخصائص المستخرجة

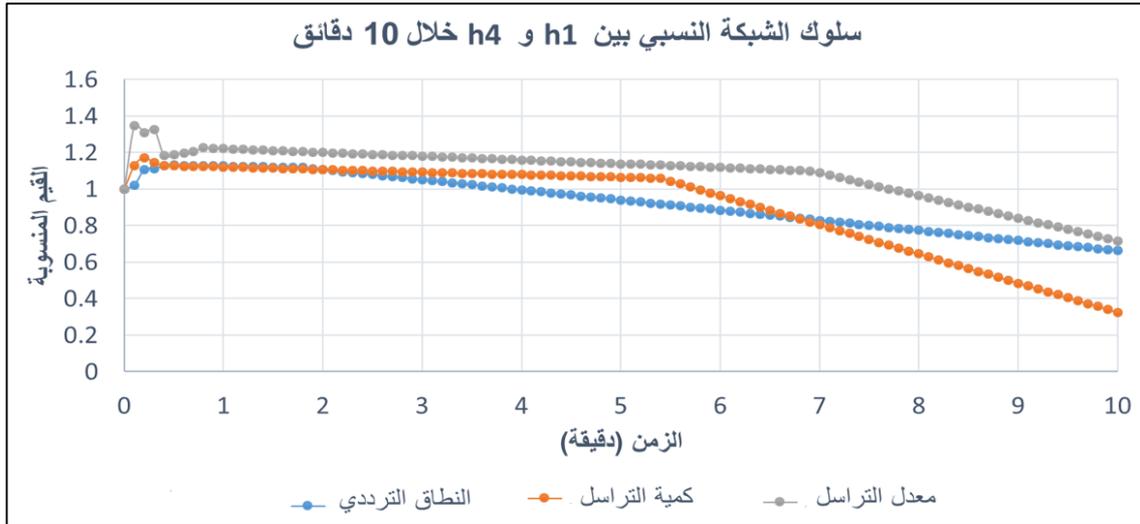
من خلال الاطلاع على النتائج السابقة لموازنة الاحمال باستخدام عرض نطاق ترددي ثابت 100 Mbps في الشكل (3)، يمكن قياس سلوك الشبكة (معدل التراسل، التأخير، والنطاق الترددي) من خلال قيمة نسبية تشير إلى مدى اختلاف الخرج مع الزمن مقارنة بالقيمة البدائية.

لتوضيح مبدأ العمل أكثر نفترض أن خرج المحاولة الأولى من كمية تراسل وعرض نطاق ترددي ومعدل تراسل هي القيم البدائية أو المرجعية، وبالتالي نسبة كل قيمة لنفسها هي 1 وعند حساب نسبة كل بارامتر خرج في المحاولات اللاحقة على المحاولة الأولى سينتج قيم نسبية، فإذا كانت القيم أصغر من 1 فهي أقل من القيمة المرجعية وإذا كانت أعلى من الواحد فهي أعلى من القيم الأولى (المرجعية).

الشكل (4) يوضح نتيجة حساب نسبة تغير المحاولات بالنسبة للمحاولة الأولى (حساب نسبة مخرجات كل محاولة الى مخرجات المحاولة الأولى)، والذي يظهر أنه كلاً من كمية التراسل الفعلية والنطاق الترددي ومعدل التراسل تعبر بطريقة واضحة عن سلوك الشبكة خلال المحاولات الخمس بما في ذلك الوصول او مؤشرات الوصول الى حالة الاختناق.

الشكل (4) يوضح معدل التغير النسبي لكل مقياس خرج في اللحظة (n) مع الحالة الأولية في اللحظة (0) وبالتالي نسبة تغير المحاولة الأولى (n=1) مساوية للواحد دائماً، والمحاولة (n+1) منسوبة للمحاولة (1). من خلال السمات المستخرجة في الشكل (4) يمكن قراءة سلوك الشبكة والتغيرات المحتملة بشكل أوضح من خلال القيم النسبية

المبسطة والتي تعبر بشكل واضح عن تحسن المخرجات أو تغييرها نحو حالة الاختناق. حيث في حالة زيادة سرعة التراسل فوق قيمة (1) فهذا يدل على الازدياد النسبي بسرعة التراسل وبالتالي أداء أفضل للشبكة والعكس صحيح وهذا يطبق أيضاً على كمية البيانات المرسله في حال معرفة مسبقة بكمية التراسل. وفي حال زيادة القيمة النسبية لعرض الحزمة المستخدم فإن الشبكة تعمل بمعدل طلبات وتراسل عاليين وبالتالي هناك احتمالية الوصول الى حالة الاختناق، حيث عندما تحاول حزم بيانات التدفق والتحرك دفعة واحدة فإن عرض النطاق الترددي غير الكافي وسيؤدي ذلك الى ازدحام في المخدمات.

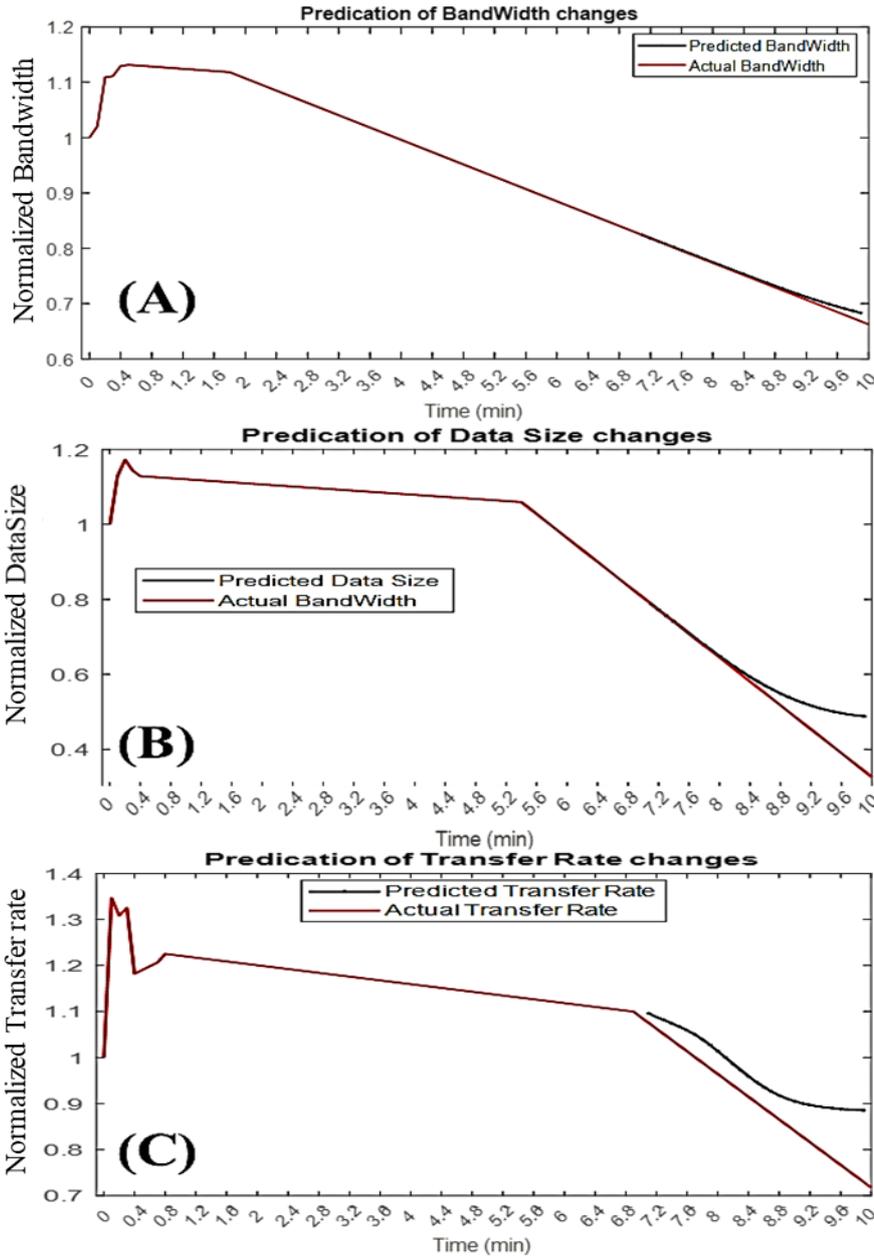


الشكل(4): المعدل النسبي لتغير المخرجات من خلال حساب نسبة خرج كل محاولة مع المحاولة الأولى.

3.4 استخدام شبكة LSTM في التنبؤ بالاختناق

يمكن استخدام الاشارات وحيدة البعد السابقة لكل متغير خرج مع شبكة LSTM التي يمكن استخدامها كأداة تنبؤ بسلوك الإشارة المستقبلية forecast [15,14]. حيث من خلال تغير الاشارات وتدريب الشبكة على معدل تغييرها يمكن التنبؤ بحدوث اختناقات. في حال حدوث اختناقات في الشبكة سيظهر ذلك من خلال انخفاض كمية التراسل ومعدل التراسل وعدم توفر عرض ترددي كاف لعمل الشبكة SDN. يظهر الشكل (5) القيم المتنبئ بها (اللون الأسود) و الحقيقية (اللون الأحمر) لكل من اشارة عرض الحزمة النسبية (الشكل 5.A)، وكمية البيانات المستقبلية (الشكل 5.B)، ومعدل التراسل (الشكل 5.C).

تظهر النتائج السابقة قدرة LSTM على إعطاء السلوك التقريبي لتغير أداء الشبكة من معدل انحراف القيم وبعدها عن الحالة الأولية، بالإضافة الى اعطاء توقع عددي تقريبي لنسبة معدل التراسل وعرض الحزمة. فيما يتعلق باستخدام أدوات التعلم العميق والذكاء الاصطناعي في تحسين موازنة الأحمال [7-9]، عملت هذه الأبحاث على تحسين موازنة الأحمال من خلال إدخال تعلم الآلة ضمن البنية الرقمية لمتمحكات SDN. بينما يقدم البحث الحالي مفهوم جديد للتخمين والتنبؤ بحالات الاختناق التي توفر انذار مبكر للخبراء من أجل التدخل بالوقت المناسب لحل مشاكل الاختناق. ويمكن دمج الطريقة المقترحة مع طرق [7-9] لتحسين بارامترات الخوارزمية في الوقت المناسب لتفادي حالات الاختناق في الوقت الحقيقي.



الشكل(5): استخدام شبكة LSTM للتنبؤ بتغيير سلوك أداء الشبكة خلال عمليات التراسل وحالات الاختناق.

5. الاستنتاجات والتوصيات

- في هذا البحث تم بناء شبكة SDN افتراضية بعدد محدد من المستخدمين والخدمات، وتم دراسة تغيير معدل التراسل وقيمة عرض الحزمة المستخدمة وزمن التأخير بعرض حزمة ثابت 100 Mbps.
- تشير قيم المقاييس (معدل التراسل، زمن التأخير، عرض الحزمة المستخدم) و معدل تغيرها على مدى كفاءة عمل الشبكة والوصول الى حالة اختناق من خلال زيادة زمن التأخير وانخفاض معدل التراسل.
- من غير المجدي استخراج سمات عديدة بقيم مطلقة واستخدامها كمدخل لخوارزميات تعلم الآلة والتعلم العميق وخاصة الشبكات العصبونية (LSTM). من خلال مفهوم استيفاء اشارات وحيدة البعد أو قيم

عددية أحادية البعد تعبر عن مدى تغير مقاييس أداء الشبكة ويقوم منسوبة الى قيمة مرجعية مثالية، يمكن أن توفر بيانات دخل معالجة مسبقاً وسهلة التحليل بالنسبة لتقنيات الذكاء الصناعي.

- توفر طريقة تتبع قيم معدل التراسل والنطاق الترددي وزمن التأخير وتحولها الى قيم نسبية (تنسيبها الى قيمة بدائية مرجعية) منهجية جديدة لدمج تقنيات الذكاء الصناعي مع مفهوم التنبؤ باختناقات الشبكات وتقييم أداء خوارزميات موازنة الأحمال.

- تظهر النتائج قدرة LSTM على إعطاء السلوك التقريبي لتغير أداء الشبكة من معدل انحراف القيم وبعدها عن الحالة الأولية، بالإضافة الى إعطاء توقع عددي تقريبي لنسبة معدل التراسل وعرض الحزمة.

- يقدم البحث الحالي مفهوم جديد للتخمين والتنبؤ بحالات الاختناق التي توفر انذار مبكر للخبراء من أجل التدخل بالوقت المناسب لحل مشاكل الاختناق.

المراجع

- [1]. Neghabi AA, Navimipour NJ, Hosseinzadeh M, Rezaee A. Load balancing mechanisms in the software defined networks: a systematic and comprehensive review of the literature. IEEE Access. 2018 Mar 5;6:14159-78.
- [2]. Lin W, Zhang L. The load balancing research of SDN based on ant colony algorithm with job classification. In 2016 2nd Workshop on Advanced Research and Technology in Industry Applications (WARTIA-16) 2016 May (pp. 472-476). Atlantis Press.
- [3]. Salman MA, Bertelle C, Sanlaville E. The behavior of load balancing strategies with regard to the network structure in distributed computing systems. In 2014 Tenth International Conference on Signal-Image Technology and Internet-Based Systems 2014 Nov 23 (pp. 432-439). IEEE.

- [4]. Yang CT, Chen ST, Liu JC, Su YW, Puthal D, Ranjan R. A predictive load balancing technique for software defined networked cloud services. *Computing*. 2019 Mar;101(3):211-35.
- [5]. Xu Y, Cello M, Wang IC, Walid A, Wilfong G, Wen CH, Marchese M, Chao HJ. Dynamic switch migration in distributed software-defined networks to achieve controller load balance. *IEEE Journal on Selected Areas in Communications*. 2019 Feb 5;37(3):515-29.
- [6]. Liu Y, Zeng Z, Liu X, Zhu X, Bhuiyan MZ. A novel load balancing and low response delay framework for edge-cloud network based on SDN. *IEEE Internet of Things Journal*. 2019 Nov 6;7(7):5922-33.
- [7]. Begam, G. S., Sangeetha, M., & Shanker, N. R. (2021). Load Balancing in DCN Servers through SDN Machine Learning Algorithm. *Arabian Journal for Science and Engineering*, 1-12.
- [8]. Rooney S, van der Merwe JE, Crosby SA, Leslie IM. The Tempest: a framework for safe, resource assured, programmable networks. *IEEE Communications Magazine*. 1998 Oct;36(10):42-53.
- [9]. YAMAMOTO K, NAITO S. ITU-T, B-ISDN ATM Layer Specification ITU-T, B-ISDN ATM Layer Specification, 1993. *IEICE transactions on information and systems*. 1999 Apr 25;82(4):870-8.
- [10]. Boucadair M, Jacquenet C. Software-defined networking: A perspective from within a service provider environment. *In RFC 7149* 2014 Mar.
- [11]. McKeown N, Anderson T, Balakrishnan H, Parulkar G, Peterson L, Rexford J, Shenker S, Turner J. OpenFlow: enabling innovation in campus networks. *ACM SIGCOMM computer communication review*. 2008 Mar 31;38(2):69-74.
- [12]. ديوب، يعرب؛ محمد، محمد؛ ميهوب، حاتم. نهج احتمالي لموازنة الحمل في منصات الحوسبة السحابية. *مجلة جامعة طرطوس للبحوث والدراسات العلمية. سلسلة العلوم الهندسية، المجلد (4)، العدد (6)، 2020.*
- [13]. علي، لبنى؛ محمود، لمى. تحسين موازنة الحمل في مراكز البيانات اعتمادا على الشبكات المعرفية بالبرمجيات. *مجلة جامعة طرطوس للبحوث والدراسات العلمية. سلسلة العلوم الهندسية، المجلد (4)، العدد (2)، 2020.*
- [14]. Zhao Z, Chen W, Wu X, Chen PC, Liu J. LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*. 2017 Mar 9;11(2):68-75.
- [15]. Muzaffar S, Afshari A. Short-term load forecasts using LSTM networks. *Energy Procedia*. 2019 Feb 1;158:2922-7.