

تحسين كفاءة التخصيص الديناميكي للموارد في الشبكات الافتراضية المعرفة برمجياً باستخدام التنبؤ الاستباقي بحركة المرور

الملخص

م. محمد أحمد مرعي¹

د. م. مياذ جابر²

mayyad.jaber@damascusuniversity.edu.sy
mohammad.merie@damascusuniversity.edu.sy

تُعد الشبكات الافتراضية المعرفة بالبرمجيات (vSDN) متعددة الشرائح من التقنيات الحديثة التي تتيح مشاركة البنية التحتية الشبكية بين عدة خدمات وشبكات افتراضية مستقلة، مما يسهم في تحسين استغلال الموارد وزيادة مرونة إدارة الشبكة. مع الطبيعة الديناميكية لحركة المرور والتغير المستمر في الأحمال الشبكية، يصبح تحقيق تخصيص فعال للموارد تحدياً رئيسياً في هذه البيئات، الأمر الذي يستدعي اعتماد آليات استباقية قادرة على التنبؤ بالطلب المستقبلي قبل حدوثه. تقدم هذه الدراسة إطاراً لتحسين كفاءة التخصيص الديناميكي للموارد يعتمد على التنبؤ الاستباقي بحركة المرور باستخدام نموذج الذاكرة طويلة قصيرة المدى (LSTM)، مع تطبيق آلية تنعيم أسّي على القيم المتنبأ بها بهدف الحد من تأثير التذبذبات قصيرة المدى وتحسين استقرار قرارات التخصيص. تعتمد آلية التخصيص المقترحة على توزيع الموارد بصورة ديناميكية وفق الاحتمال المستقبلية المتوقعة للشرائح الافتراضية، مما يتيح الاستجابة المبكرة للتغيرات المرورية وتحسين استغلال الموارد المتاحة. تم تقييم النموذج المقترح ضمن بيئة محاكاة متكاملة تعتمد على Mininet و ONOS و Libera Hypervisor، مع دراسة أثر التنعيم على دقة التنبؤ واستقرار التخصيص وكفاءة استغلال الموارد. أظهرت النتائج العملية أن دمج التنعيم الأسّي مع نموذج LSTM أسهم في خفض التذبذبات الحادة وتقليل عمليات إعادة التخصيص غير الضرورية، حيث حقق النموذج متوسط مؤشر جودة خدمة كلي QoS بلغ 0.82 بمعدل تحسين 7.5% مقارنة بإطار DLVisor و 37.4% مقارنة بالتخصيص الثابت، ونجح في تقليل معدل انتهاك اتفاقية مستوى الخدمة (SLA) للشريحة الحرجة إلى 5% فقط بنسبة خفض بلغت 50% مقارنة بإطار DLVisor كما أثبت الإطار المقترح كفاءة عالية في الحد من هدر الموارد بمعدلات تحسن نسبية تجاوزت 50% مقارنة بالتخصيص الثابت عبر كافة الشرائح، وخفض للهدر بنسبة 38.46% و 22.22% مقارنة بـ DLVisor في الشريحتين

الدرجة والفيديو على التوالي. من الناحية الحسابية، حافظ الإطار على تعقيد خطي $O(S)$ وزمن تنفيذ منخفض لدورة اتخاذ القرار تراوح بين 4.82 ms عند 3 شرائح ولم يتجاوز 8.15 ms عند الكثافة التشغيلية العالية (12 شريحة)، متفوقاً في سرعة الاستجابة بنسبة 83.1% مقارنة بإطار DLVisor الذي سجل 48.30 ms عند نفس الكثافة. تؤكد هذه النتائج الرقمية أن النموذج المقترح يضمن البقاء ضمن حدود حلقة التحكم الدرجة للشبكة < (Real-Time Control Loop (10 ms)، مما يجعله نهجاً فعالاً وقابلاً للتوسع لتحسين كفاءة التخصيص الديناميكي للموارد وتعزيز استقرار الأداء في الشبكات الافتراضية المعرفة بالبرمجيات متعددة الشرائح. الكلمات المفتاحية: التخصيص الديناميكي للموارد، التنبؤ بحركة المرور، الشبكات المعرفة بالبرمجيات، الشبكات الافتراضية متعددة الشرائح، LSTM، التعميم الأسّي، استغلال الموارد، جودة الخدمة.

1- مهندس في قسم النظم والشبكات الحاسوبية - كلية الهندسة المعلوماتية - جامعة دمشق.

2- مدرس في قسم النظم والشبكات الحاسوبية - كلية الهندسة المعلوماتية - جامعة دمشق.

Improving Dynamic Resource Allocation Efficiency in Software-Defined Virtual Networks Using Proactive Traffic Forecasting

Abstract

Eng. Mohammad Merie
Jaber

Dr. Eng. Mayyad

mohammad.merie@damascusuniversity.edu.sy

mayyad.jaber@damascusuniversity.edu.sy

Multi-slice Virtual Software-Defined Networking (vSDN) represents a prominent paradigm that enables the sharing of underlying physical infrastructure across multiple independent virtual networks and services, thereby enhancing resource utilization and network management flexibility. Given the dynamic nature of network traffic and continuous load fluctuations, achieving efficient dynamic resource allocation poses a primary challenge in these environments, necessitating proactive mechanisms capable of forecasting future demand prior to its occurrence.

proposes a framework to enhance dynamic resource allocation efficiency based on proactive traffic forecasting using a Long Short-Term Memory (LSTM) model, combined with an exponential smoothing mechanism applied to predicted values to mitigate short-term fluctuations and stabilize allocation decisions. The proposed scheme dynamically distributes resources according to expected future loads of virtual slices, enabling early responses to traffic variations and optimizing resource utilization. The framework was evaluated within an integrated simulation environment based on Mininet, ONOS, and Libera Hypervisor, analyzing the impact of exponential smoothing on prediction accuracy, allocation stability, and resource utilization. Experimental results demonstrated that combining exponential smoothing efficiency with the LSTM model significantly mitigated sharp oscillations and reduced unnecessary reallocations. The proposed model achieved an overall average Quality of Service (QoS) index of 0.82 (representing an improvement of 7.5% over the DLVisor framework and 37.4% over static allocation) and successfully reduced the Service Level Agreement (SLA) violation rate for critical slices to just 5% (a 50% reduction compared to DLVisor). Furthermore, the framework exhibited high efficiency in reducing resource wastage, achieving relative improvement rates exceeding 50% across all slices compared to static allocation, and lowering wastage by 38.46% and 22.22% compared to DLVisor for critical and video slices, respectively. Computationally, the framework maintained linear complexity $O(S)$ with a low decision-cycle execution time ranging from 4.82 ms for 3 slices to no more than 8.15 ms under high operational density (12 slices), outperforming DLVisor in response speed by 83.1% (48.30 ms at the same scale). These numerical findings confirm that the proposed model strictly operates within the critical boundaries of the real-time control loop (Real-Time Control Loop < 10 ms), establishing it as an effective and scalable approach for optimizing dynamic resource allocation and enhancing performance stability in multi-slice virtual software-defined networks.

Keywords: Dynamic Resource Allocation, Proactive Traffic Forecasting, Software-Defined Networking, Virtual Network Virtualization, LSTM, Exponential Smoothing, Resource Utilization, Allocation Stability, Quality of Service (QoS).

1- مقدمة

أدى التطور المتسارع لتطبيقات الجيل الخامس وما بعده، والاعتماد الواسع على تقنية تقطيع الشبكة (Network Slicing)، إلى زيادة الحاجة إلى آليات فعالة لإدارة الموارد في البيئات الافتراضية. أسهمت الشبكات المعرفة بالبرمجيات (SDN) في دعم هذا التوجه من خلال فصل مستوى التحكم عن مستوى البيانات، مما وقّر مرونة أكبر في إدارة الشبكات وتخصيص مواردها [1]. مع ظهور الشبكات الافتراضية المعرفة بالبرمجيات متعددة الشرائح (vSDN)، أصبح من الممكن مشاركة البنية التحتية الفيزيائية بين شرائح افتراضية مستقلة، بما يدعم تحسين استغلال الموارد وخفض التكاليف التشغيلية [15]. تتمثل المشكلة البحثية في أن التغيرات المفاجئة في الأحمال المرورية قد تؤدي إلى انخفاض كفاءة تخصيص الموارد وتذبذب القرارات التشغيلية. كما أن اعتماد بعض آليات التخصيص على الاستجابة للتغيرات بعد وقوعها قد يحد من قدرتها على التعامل المبكر مع الطلب المتغير، ولا سيما في البيئات متعددة الشرائح. لمعالجة هذه المشكلة، برزت نماذج التعلم العميق، ولا سيما نموذج الذاكرة طويلة قصيرة المدى (LSTM)، بوصفها أدوات مناسبة للتنبؤ بالأحمال المستقبلية ودعم اتخاذ قرارات تخصيص استباقية [9]. إلا أن استخدام التنبؤات الخام مباشرة قد ينقل التذبذبات قصيرة المدى أو الأخطاء المحدودة إلى قرارات التخصيص، بما يؤدي إلى تغيرات متكررة في حصص الموارد. انطلاقاً من ذلك، تقدم هذه الدراسة إطاراً يعتمد على نموذج LSTM للتنبؤ بحركة المرور، مع تطبيق التنعيم الأسّي على القيم المنتبأ بها قبل استخدامها في تخصيص الموارد. وتركز مساهمة الدراسة على تحليل أثر التنعيم في استقرار قرارات التخصيص وكفاءة استغلال الموارد، من خلال مقارنة التخصيص المعتمد على التنبؤ الخام بالتخصيص المعتمد على التنبؤ المنعّم ضمن بيئة تجريبية تستخدم Mininet و ONOS [3] و Libera Hypervisor [14].

2- الدراسة المرجعية

شهدت السنوات الأخيرة اهتماماً متزايداً بتطوير آليات ذكية لإدارة الموارد في بيئات الشبكات المعرفة بالبرمجيات (SDN) والشبكات الافتراضية متعددة الشرائح، مدفوعاً بالتوسع المستمر في تطبيقات

الجيلين الخامس والسادس ومتطلبات تقطيع الشبكة (Network Slicing). ركزت الدراسات الحديثة على توظيف نماذج التنبؤ بحركة المرور وآليات التخصيص الديناميكي للموارد بهدف تحسين استغلال الموارد والتكيف مع تغيرات الأحمال الشبكية. سعت العديد من الأبحاث إلى تعزيز استقرار قرارات التخصيص وتقليل التعقيد الحسابي وزمن الاستجابة باستخدام تقنيات التعلم الآلي والتعلم العميق وخوارزميات التحسين المختلفة. فيما يلي عرض لأهم الدراسات المرتبطة بموضوع البحث.

تناولت الدراسات السابقة إدارة الموارد في الشبكات متعددة الشرائح من اتجاهات تقنية مختلفة، شملت التنبؤ بحركة المرور، والتخصيص الاستباقي للموارد، والأساليب التفاعلية القائمة على التحسين أو التعلم التعزيزي، إضافة إلى آليات الحد من إعادة تشكيل الشرائح. ويختلف كل اتجاه في نوع البيانات المستخدمة، وآلية اتخاذ القرار، والتعقيد الحسابي، ومدى ملائحته للتشغيل في الزمن الحقيقي.

الدراسات المعتمدة على التنبؤ بحركة المرور

قدمت الدراسة [12] إطاراً للتنبؤ بحركة المرور في شبكات الجيل الخامس المعتمدة على SDN باستخدام نموذج Convolutional Diffusion GRU، بهدف تمثيل العلاقات المكانية والزمانية في حركة المرور. أظهرت النتائج تحسناً في دقة التنبؤ وانخفاضاً في مؤشرات الخطأ مقارنة بالنماذج التقليدية. تتمثل قوة هذا العمل في بناء نموذج قادر على تمثيل أنماط المرور المعقدة، إلا أن نطاقه اقتصر على التنبؤ، دون تقييم مباشر لأثر المخرجات التنبؤية في استقرار قرارات تخصيص الموارد.

في اتجاه أكثر ارتباطاً بإدارة الموارد، جمعت الدراسة [4] بين نماذج LSTM و Transformers ونظام Telemetry للتنبؤ باستهلاك الموارد ودعم إدارة دورة حياة وظائف الشبكة الافتراضية (VNFs). قدمت الدراسة دقة تنبؤية مرتفعة وإدارة محسنة للموارد على مستوى الوظائف الافتراضية، غير أن نطاقها انحصر في موارد المعالجة الخاصة بوظائف الشبكة، ولم يركز بصورة مباشرة على تخصيص عرض النطاق الترددي بين شرائح vSDN أو على أثر استقرار التنبؤ في تغيرات قرارات التخصيص.

تُظهر المقارنة بين الدراستين [12] و[4] أن نماذج التنبؤ المتقدمة تستطيع تحسين تقدير الأحمال المستقبلية، إلا أن دقة التنبؤ وحدها لا تكفي لتقييم كفاءة إدارة الموارد؛ إذ ينبغي أيضاً تحليل كيفية استخدام المخرجات التنبؤية، ومدى تأثير تقلباتها في استقرار قرارات التخصيص.

الدراسات التي تربط التنبؤ بتخصيص الموارد

قدمت الدراسة [5] إطار DLVisor بوصفه مشرفاً افتراضياً يعتمد على التعلم الديناميكي والتنبؤ المستقبلي لتحسين توزيع الموارد بين شرائح vSDN. يتميز الإطار بدمج النموذج التنبؤي مع آلية العرض والطلب، والاستفادة من الطلب المتوقع في تصنيف الشرائح المزودة والبالغة للموارد. كما يهدف إلى تقليل فرط الاستغلال والحد من تعرض الشرائح المزودة لحرمان الموارد بعد تقديم ساعاتها الفائضة. في المقابل، تعتمد آلية DLVisor على تصنيف الشرائح باستخدام حدود تشغيلية محددة، ثم إجراء حسابات العرض والطلب ودالة التكلفة. ولذلك تتأثر كفاءة القرار بدقة التنبؤ، واختيار حدود التصنيف، وعدد الشرائح المزودة والبالغة. كما أن استخدام تنبؤات متعددة الخطوات وحسابات العرض والطلب يضيفان عبئاً حسابياً مقارنة بآليات التخصيص المباشر منخفضة التعقيد. يمثل DLVisor مرجعاً مناسباً للمقارنة في الدراسة الحالية لأنه يربط التنبؤ بإعادة تخصيص الموارد فعلياً، بخلاف الدراسات التي تقتصر على التنبؤ ومع ذلك، تختلف الدراسة الحالية عنه في تركيزها على قياس أثر معالجة التنبؤات بالتنعيم الأسّي قبل اتخاذ قرار التخصيص، وتحليل العلاقة بين تقلب القيم المتنبأ بها واستقرار حصص الموارد الناتجة.

الدراسات التفاعلية القائمة على الأولوية والتحسين

تناولت الدراسة [11] مشكلة التنافس على الموارد وتحقيق متطلبات اتفاقيات مستوى الخدمة من خلال نموذج قائم على Intent-Based Networking لإدارة دورة حياة النوايا وتخصيص الموارد بين شرائح الشبكة. أظهرت النتائج قدرة النموذج على دعم متطلبات الشرائح الحساسة، ولا سيما شريحة uRLLC. إلا أن إعطاء أولوية مرتفعة لهذه الشريحة انعكس على الموارد المتاحة لشرائح eMBB و mMTC، مما يوضح وجود مقايضة بين حماية الخدمات الحرجة والمحافظة على أداء بقية الشرائح.

أما الدراسة [7] فقد استخدمت التعلم التعزيزي العميق متعدد الوكلاء (MARL) لإدارة الموارد في شبكات الجيل السادس متعددة الشرائح. وحقق النموذج معدلات مرتفعة في استغلال الموارد والإنتاجية والرضا عن جودة الخدمة. وتتميز هذه الآلية بقدرتها على تعلم سياسات تخصيص معقدة، غير أنها تتطلب حلقات تدريب وتفاعل حتى الوصول إلى سياسة مستقرة، مما يزيد زمن التقارب والعبء الحسابي. بصورة مشابهة، جمعت الدراسة [10] بين التعلم التعزيزي متعدد الوكلاء ونظرية الألعاب التطورية (EGT) لتنسيق الموارد بين شرائح eMBB و uRLLC و mMTC في بيئات MEC. حققت زمناً منخفضاً للاستجابة ومعدلات مرتفعة لاستغلال الموارد، إلا أن مراحل التعلم والتقارب قد يصاحبها تغير في السياسات وعدم استقرار مؤقت قبل الوصول إلى الحالة المستقرة. يوضح تحليل هذه الدراسات أن الأساليب التفاعلية والتحسينية تتميز بقدرتها على التعامل مع متغيرات وقيود متعددة، لكنها تتطلب غالباً عمليات تعلم أو تحسين إضافية. لذلك ترتبط ملاءمتها للتشغيل الفوري بالموازنة بين جودة القرار والكلفة الحسابية وزمن التقارب، ولا يمكن تقييمها اعتماداً على استغلال الموارد وحده.

الدراسات المعنية باستقرار التخصيص

ركزت الدراسة [13] بصورة مباشرة على تقليل عمليات إعادة تشكيل الشرائح، باستخدام نموذج هجين يجمع بين التعلم التعزيزي العميق والبرمجة الخطية. وأظهرت النتائج انخفاضاً في عمليات إعادة التشكيل بنسبة بلغت نحو 11% مقارنة بالأساليب المرجعية، وهو ما يمثل معالجة مباشرة لأحد جوانب استقرار إدارة الشرائح. تختلف معالجة الاستقرار في الدراسة [13] عن التوجه المتبع في الدراسة الحالية؛ إذ تعالج الدراسة [13] تكلفة إعادة التشكيل على مستوى قرار إدارة الشرائح، بينما تركز الدراسة الحالية على مصدر سابق للقرار، يتمثل في تقلب القيم المتنبأ بها قبل تحويلها إلى حصص من الموارد. بذلك لا تمثل الدراستان بديلين مباشرين، بل تعالجان الاستقرار عند مرحلتين مختلفتين من سلسلة اتخاذ القرار.

التحليل المقارن

تكشف المقارنة بين الدراسات السابقة عن وجود ثلاثة اتجاهات رئيسية. يركز الاتجاه الأول على تحسين دقة التنبؤ، لكنه لا يقيس دائماً أثر تقلب التنبؤات في قرارات التخصيص. يربط الاتجاه الثاني التنبؤ

بإدارة الموارد مباشرة، كما في DLVisor ، لكنه يستخدم آليات إضافية لتصنيف الشرائح وحساب العرض والطلب. أما الاتجاه الثالث، فيعتمد على التعلم التعزيزي أو التحسين الرياضي، ويوفر قرارات متعددة المعايير مقابل زيادة محتملة في التعقيد وزمن التقارب. لا تعني هذه الاختلافات أن اتجاهاً واحداً يتفوق بصورة مطلقة؛ فالدراسات التنبؤية أكثر ملاءمة لتقدير الطلب المستقبلي، بينما تستوعب نماذج التعلم التعزيزي والتحسين عدداً أكبر من القيود، وتتعامل نماذج إعادة التشكيل مباشرة مع استقرار القرارات. مع ذلك، يبقى أثر استقرار المخرجات التنبؤية نفسها في استقرار التخصيص بحاجة إلى تقييم كمي مباشر، ولا سيما عند مقارنة استخدام التنبؤ الخام باستخدام التنبؤ المنعم ضمن بيئة تشغيل موحدة.

الفجوة البحثية (Research Gap)

أظهر تحليل الدراسات السابقة وجود اهتمام متزايد بربط التنبؤ بحركة المرور بقرارات إدارة الموارد وتخصيصها في البيئات الافتراضية. استخدمت دراسات عديدة نماذج التعلم الآلي والتعلم العميق، ومنها نموذج LSTM، لتقدير الاحتمال المستقبلية والاستفادة منها في إعادة تخصيص الموارد أو توسيعها استباقياً. لذلك، لا يمثل دمج التنبؤ بعملية التخصيص فجوة بحثية مستقلة أو مساهمة جديدة بحد ذاته. مع ذلك، ركزت معظم هذه الدراسات على تحسين دقة التنبؤ أو كفاءة تخصيص الموارد، بينما حظي أثر استقرار القيم المنتبأ بها في استقرار قرارات التخصيص باهتمام أقل، ولا سيما في بيئات الشبكات الافتراضية المعرفة بالبرمجيات متعددة الشرائح (vSDN). فقد تؤدي التذبذبات قصيرة المدى في مخرجات النموذج التنبؤي، عند استخدامها مباشرة، إلى تغيرات متكررة في الحصص المخصصة وعمليات إعادة تخصيص غير ضرورية، حتى وإن كانت دقة التنبؤ العامة مقبولة.

بناءً على ذلك، تتمثل الفجوة البحثية في الحاجة إلى تحليل أثر معالجة مخرجات التنبؤ زمنياً قبل إدخالها في قرار التخصيص، ودراسة الموازنة بين تقليل التذبذب والمحافظة على سرعة الاستجابة للتغيرات الفعلية في الحمل. وانطلاقاً من هذه الفجوة، تقترح الدراسة تطبيق التعقيم الأسّي على مخرجات نموذج LSTM، ثم مقارنة التخصيص المعتمد على التنبؤ الخام بالتخصيص المعتمد على التنبؤ المنعم، بهدف تقييم أثر التعقيم في استقرار قرارات التخصيص، وعدد عمليات إعادة التخصيص، وكفاءة استغلال الموارد، مع المحافظة على تعقيد حسابي منخفض.

المرجع والسنة	آلية إدارة الموارد	استخدام التنبؤ في إدارة الموارد	معالجة استقرار التنبؤ قبل القرار	التعقيد النسبي
[12]، 2022	تنبؤ بحركة المرور فقط	غير مطبق في تخصيص الموارد	غير مدروس	منخفض
[5]، 2023	تخصيص استباقي قائم على العرض والطلب	مدعوم	مدعوم جزئياً من خلال تنعيم بيانات التنبؤ	مرتفع
[11]، 2024	تخصيص تفاعلي قائم على النوايا والأولوية	غير مدعوم	غير مدروس	متوسط
[13]، 2025	تعلم تعزيزي عميق وبرمجة خطية لتقليل إعادة التشكيل	غير مدعوم	يعالج استقرار إعادة التشكيل، لا استقرار التنبؤ	مرتفع
[7]، 2026	تعلم تعزيزي متعدد الوكلاء	غير مدعوم بصورة مستقلة	غير مدروس	مرتفع
[4]، 2026	تنبؤ باستخدام LSTM Transformers و VNFS وإدارة	مدعوم	غير محلل من حيث أثره في استقرار التخصيص	مرتفع
[10]، 2026	تعلم تعزيزي متعدد الوكلاء ونظرية الألعاب	غير مدعوم بصورة مستقلة	غير مدروس	مرتفع
الإطار المقترح	تخصيص استباقي قائم على التنبؤ المنعم	مدعوم	يتم تقييم أثره مباشرة من خلال مقارنة التنبؤ الخام والمنعم	منخفض

الجدول (1): التحليل المقارن للدراسات السابقة والإطار المقترح

يوضح الجدول (1) أن الدراسات السابقة اعتمدت اتجاهات تقنية مختلفة في إدارة الموارد؛ فقد ركزت بعض الدراسات على تحسين دقة التنبؤ بحركة المرور، بينما استخدمت دراسات أخرى مخرجات التنبؤ بصورة مباشرة في إعادة تخصيص الموارد أو توسيعها. كما تناولت بعض الأعمال استقرار إدارة الموارد من خلال تقليل عمليات إعادة تشكيل الشرائح أو استخدام آليات تعلم وتحسين متقدمة. مع ذلك، لم يكن أثر استقرار المخرجات التنبؤية في استقرار قرارات التخصيص محورياً رئيساً في معظم الدراسات. لذلك، تركز الدراسة الحالية على تقييم أثر تطبيق التنعيم الأسّي قبل اتخاذ القرار، من خلال مقارنة

التخصيص المعتمد على التنبؤ الخام بالتخصيص المعتمد على التنبؤ المنعم، مع تحليل أثر ذلك في تقلب الحصص، وعدد عمليات إعادة التخصيص، وكفاءة استغلال الموارد.

3- آلية التخصيص الاستباقي المقترحة

تقدم هذه الدراسة آلية استباقية منخفضة التعقيد لتخصيص الموارد في بيئات الشبكات الافتراضية المعرفة بالبرمجيات متعددة الشرائح (vSDN)، تعتمد على التنبؤ بالأحمال المستقبلية باستخدام نموذج الذاكرة طويلة قصيرة المدى (LSTM)، ومعالجة القيم المتنبأ بها بالتنعيم الأسّي قبل استخدامها في اتخاذ قرار التخصيص. تركز الدراسة على تحليل أثر التنعيم في الحد من التقلبات قصيرة المدى في مخرجات التنبؤ، وانعكاس ذلك على استقرار الحصص المخصصة وكفاءة استغلال الموارد.

تبدأ الآلية بجمع قيم استغلال الموارد لكل شريحة، ثم استخدام نموذج LSTM المدرب مسبقاً للتنبؤ بالحمل خلال الفترة الزمنية التالية وبعد ذلك، يُطبق التنعيم الأسّي على القيم المتنبأ بها قبل تحويلها إلى حصص نسبية تُستخدم في توزيع السعة المتاحة بين الشرائح النشطة. يُقيم أثر التنعيم من خلال مقارنة التخصيص المعتمد على التنبؤ الخام بالتخصيص المعتمد على التنبؤ المنعم، باستخدام مؤشرات كمية تقيس تغير الحصص المخصصة وعدد عمليات إعادة التخصيص وكفاءة استغلال الموارد. كما تتضمن الآلية معالجة الحالات الحدية، مثل غياب الطلب عن جميع الشرائح، وظهور الأحمال الانفجارية، وارتفاع خطأ التنبؤ. يُستكمل وصفها بخوارزمية شبه برمجية وتحليل للتعقيد الحسابي، بهدف توضيح خطوات التنفيذ وقابلية التطبيق ضمن البيانات ذات متطلبات الاستجابة السريعة.

تتكون الآلية المقترحة من المراحل الرئيسية الآتية:

1. جمع بيانات استغلال الموارد ومراقبة حركة المرور.
2. التنبؤ بالأحمال المستقبلية باستخدام نموذج LSTM.
3. تطبيق التنعيم الأسّي على القيم المتنبأ بها.
4. تحديد الشرائح النشطة ومعالجة حالة غياب الطلب.
5. حساب الحصص النسبية وتخصيص الموارد.
6. تطبيق قرارات التخصيص وتحديث النافذة الزمنية.

7. تقييم استقرار التخصيص والمتانة تجاه الأحمال الانفجارية وأخطاء التنبؤ.

3-1 التنبؤ بالأحمال المستقبلية باستخدام LSTM

يعتمد الإطار على نموذج الذاكرة طويلة قصيرة المدى (LSTM) للتنبؤ بالحمل المستقبلي لكل شريحة افتراضية. يُدرَّب النموذج باستخدام بيانات الاستغلال التاريخية، نظراً إلى قدرته على تمثيل العلاقات الزمنية قصيرة وطويلة المدى في السلاسل الزمنية.

خلال التشغيل، تُمرر نافذة زمنية تتكون من آخر 14 قيمة استغلال متاحة للشريحة i :

$$[U_i(t-13), U_i(t-12) \dots U_i(t)]$$

إلى نموذج LSTM المدرب مسبقاً للحصول على التنبؤ الخام بالحمل خلال الفترة الزمنية التالية:

$$\hat{L}_i(t+1)$$

حيث تمثل $\hat{L}_i(t+1)$ قيمة الحمل الخام المتوقع للشريحة i خلال الفترة الزمنية $t+1$. تقتصر عملية النموذج أثناء التشغيل على الاستدلال (Inference) دون إعادة تدريب النموذج أو تحديث أوزانه.

3-2 التعيم الأسّي للقيم المتنبأ بها

قد تتضمن مخرجات التنبؤ الخام تقلبات قصيرة المدى تنتقل إلى قرارات تخصيص الموارد عند استخدامها مباشرة. لذلك، يُطبَّق التعيم الأسّي على القيمة المتنبأ بها وفق العلاقة الآتية:

$$L_i^S(t+1) = \lambda \hat{L}_i(t+1) + (1-\lambda)L_i^S(t)$$

حيث تمثل:

- $\hat{L}_i(t+1)$: الحمل الخام المتوقع الناتج عن نموذج LSTM للشريحة i خلال الفترة الزمنية التالية.
- $L_i^S(t)$: القيمة المنعّمة في دورة التنبؤ السابقة.
- $L_i^S(t+1)$: الحمل المتوقع بعد تطبيق التعيم الأسّي في دورة التنبؤ الحالية.
- λ : معامل التعيم الزمني، بحيث:

$$0 \leq \lambda \leq 1$$

تمثل قيمة λ وزن التنبؤ الخام الحالي، بينما يمثل $(1 - \lambda)$ وزن القيمة المنعّمة السابقة. تؤدي القيم المنخفضة لـ λ إلى زيادة الاعتماد على القيمة السابقة، مما يحد من التغيرات قصيرة المدى ويزيد استقرار الإشارة، لكنه قد يؤدي إلى تأخر الاستجابة للتغيرات الجديدة في الحمل. في المقابل، تمنح القيم المرتفعة لـ λ وزناً أكبر للتنبؤ الحالي، مما يسرّع استجابة النظام، لكنه قد يزيد حساسية قرارات التخصيص للقلبات والضجيج وأخطاء التنبؤ. ولا تفترض الدراسة أن تطبيق التعيم يؤدي تلقائياً إلى تحسين استقرار التخصيص؛ بل تُقِيم أثره تجريبياً من خلال مقارنة التخصيص المعتمد على التنبؤ الخام بالتخصيص المعتمد على التنبؤ المنعّم. كما تُحدد قيمة λ المستخدمة وفق موازنة تجريبية بين دقة التنبؤ، ونقلب قرارات التخصيص، والتأخر الزمني في الاستجابة ضمن القيم والسيناريوهات المختبرة، بدلاً من وصفها بأنها قيمة مثلى بصورة مطلقة.

3-3 تحديد الشرائح النشطة

قد لا يوجد طلب حالي أو متوقع على بعض الشرائح خلال إحدى دورات التخصيص. لذلك، يُحدد نشاط الشريحة i وفق مؤشر ثنائي:

$$I_i(t+1) = \begin{cases} 1, & U_i(t) > 0 \vee L_i^S(t+1) > 0 \\ 0, & U_i(t) = 0 \wedge L_i^S(t+1) = 0 \end{cases}$$

حيث تشير القيمة $I_i(t+1) = 1$ إلى وجود طلب حالي أو متوقع على الشريحة، بينما تشير القيمة $I_i(t+1) = 0$ إلى غياب كليهما. بعد ذلك، يُحسب الحمل الفعّال للشريحة:

$$L_i^a(t+1) = I_i(t+1)L_i^S(t+1)$$

بذلك تدخل الشرائح النشطة فقط في عملية توزيع موارد البيانات. لا يُعد عدم تخصيص الموارد لشريحة غير نشطة حالة حرمان من الموارد، لعدم وجود طلب حالي أو متوقع عليها.

3-4 حساب الحصة النسبية للشرائح

بعد تحديد الأحمال الفعّالة، يُحسب مجموعها وفق:

$$L_{\text{tot}}^a(t+1) = \sum_{j=1}^N L_j^a(t+1)$$

ثم تُحسب الحصة النسبية للشريحة i وفق:

$$W_i(t+1) = \begin{cases} \frac{L_i^a(t+1)}{\sum_{j=1}^N L_j^a(t+1)}, & L_{\text{tot}}^a(t+1) > 0 \\ 0, & L_{\text{tot}}^a(t+1) = 0 \end{cases}$$

حيث يمثل N عدد الشرائح الافتراضية المُدارة في النظام، وتمثل $W_i(t+1)$ الحصة النسبية للشريحة i .

عند وجود شريحة نشطة واحدة على الأقل، تحقق الحصص الشرط:

$$\sum_{i=1}^N W_i(t+1) = 1$$

أما عندما يكون:

$$L_{\text{tot}}^a(t+1) = 0$$

فإن ذلك يعني غياب الطلب الحالي والمتوقع عن جميع الشرائح. في هذه الحالة تُضبط الحصص عند الصفر، مما يمنع القسمة على الصفر وتخصيص موارد لشرائح غير نشطة.

3-5 تخصيص الموارد

تُحوّل الحصص النسبية إلى موارد فعلية وفق العلاقة:

$$R_i(t+1) = C_{\text{tot}} W_i(t+1)$$

حيث تمثل $R_i(t+1)$ مقدار الموارد المخصصة للشريحة i خلال الفترة الزمنية التالية، ويمثل C_{tot} إجمالي السعة المتاحة.

عند وجود شريحة نشطة واحدة على الأقل، يكون:

$$\sum_{i=1}^N R_i(t+1) = C_{\text{tot}}$$

وبذلك تُوزع السعة الكلية بين الشرائح النشطة بصورة تتناسب مع أحمالها المستقبلية المنعّمة.

أما إذا لم توجد أي شريحة نشطة، فإن:

$$R_i(t+1) = 0, \forall i$$

تبقى السعة متاحة إلى حين ظهور طلب حالي أو متوقع في دورة تخصيص لاحقة. تتميز هذه الآلية بانخفاض كلفتها الحسابية، إذ تعتمد على تنفيذ عدد ثابت من العمليات لكل شريحة، دون استخدام خوارزميات تحسين تكرارية أو حلقات تعلم إضافية أثناء التشغيل. ومع ذلك، لا يُفترض أن بساطة معادلة التخصيص تؤدي تلقائياً إلى استقرار أفضل؛ بل يُقِيم أثر التنعيم بصورة كمية في قسم النتائج من خلال مقارنة التنبؤ الخام والتنبؤ المنعم باستخدام مؤشرات تغير الحصص وعدد عمليات إعادة التخصيص وكفاءة استغلال الموارد.

3-6 الشفرة الوصفية للآلية المقترحة (Pseudocode)

تُلخّص الشفرة الوصفية الموضحة في (Algorithm 1) التسلسل التنفيذي البرمجي للآلية المقترحة لتخصيص الموارد الاستباقي. تُنفَّذ الخوارزمية بشكل دوري ضمن حلقة تحكم زمنية قابلة للضبط ($\Delta t = 2s$)، حيث تبدأ بقراءة القياسات اللحظية، ثم تنفيذ التنبؤ والتنعيم الأسّي، وتحديد الأحمال الفعّالة والحصص النسبية مع معالجة الحالات الحدية (كغياب الطلب أو التعرض لأحمال انفجارية)، وصولاً إلى حقن سياسات الجودة (QoS) في مفاتيح ($Open vSwitch (OVS)$

Algorithm 1: Proactive vSDN Slice Resource Allocation Framework

Input :

- Historical load window for each slice S_i : $[T_i(t-k+1), \dots, T_i(t)]$
- Pre-trained LSTM model weights Θ
- Exponential smoothing factor γ in $(0, 1)$
- Total substrate network capacity C_{tot}
- Minimum guaranteed bandwidth thresholds B_i^{min}
- Control loop update interval $\Delta t = 2s$

Output:

- Bandwidth Allocation Vector $B(t+1) = [B_1(t+1), \dots, B_N(t+1)]$
- Flow Rule updates for OVS Meter Tables

1: Initialize ONOS Controller, Libera Hypervisor, and OVS Interfaces

2: Loop continuously every $\Delta t = 2s$:

4: // Phase 1: Raw Traffic Prediction using LSTM (3-1)

```
5:   For each slice i = 1 to N do:
6:       D_raw_i(t+1) = LSTM_Inference([T_i(t-k+1), ..., T_i(t)]; Theta)
7:   End For
9: // Phase 2: Exponential Smoothing Application (3-2)
10:  For each slice i = 1 to N do:
11:      D_smooth_i(t+1) = gamma * D_raw_i(t+1) + (1 - gamma) *
D_smooth_i(t)
12:  End For
13: // Phase 3: Active Slice Identification & Effective Load L_i^a(t+1) (3-3)
14:  For each slice i = 1 to N do:
15:      If (T_i(t) > 0 OR D_smooth_i(t+1) > 0) Then:
16:          A_i(t) = 1
17:      Else:
18:          A_i(t) = 0
19:      End If
20:      L_i^a(t+1) = A_i(t) * D_smooth_i(t+1)
21:  End For
22:  // Phase 4: Total Effective Load & Relative Portion W_i(t+1)
Calculation (3-4)
23:  L_tot_a(t+1) = Sum(L_j^a(t+1)) for j = 1 to N
24:  If L_tot_a(t+1) == 0 Then:
25:      For i = 1 to N do:
26:          W_i(t+1) = 0
27:          B_i(t+1) = 0
28:      End For
29:  Else:
```

```

30:      For i = 1 to N do:
31:           $W_i(t+1) = L_i^a(t+1) / L_{tot\_a}(t+1)$ 
32:      // Phase 5: Resource Allocation & SLA Protection (3-5)
33:          If  $A_i(t) == 1$  Then:
34:               $B_i(t+1) = \text{Max}( W_i(t+1) * C_{tot}, B_i^{min} )$ 
35:          Else:
36:               $B_i(t+1) = 0$ 
37:          End If
38:      End For
39:  End If
40:  // Phase 6: Hardware Execution & OpenFlow Policy Injection
41:  Generate OpenFlow QoS meter rules corresponding to  $B(t+1)$ 
42:  Inject rules via ONOS REST API to update OVS flow tables in Data
  Plane
43:  Update historic buffers for the next control cycle ( $t + 1$ )
44:  End Loop

```

4- المعمارية المستخدمة

تُقسم المعمارية إلى مسارين مستقلين: مسار التدريب الذي يُنفذ خارج بيئة التشغيل الفعلية، ومسار التنفيذ الذي يستخدم النموذج المدرب مسبقاً ضمن حلقة التشغيل. يهدف هذا الفصل إلى إبقاء العمليات التدريبية مرتفعة الكلفة خارج المسار التشغيلي، بحيث يقتصر عمل النموذج أثناء التنفيذ على الاستدلال (Inference).

4-1 معمارية التدريب (Training Architecture)

تعتمد معمارية التدريب على بيانات تاريخية تمثل قيم استغلال عرض النطاق الترددي للشرائح الافتراضية. تبدأ مرحلة التدريب بترتيب السجلات زمنياً ومعالجة القيم المفقودة والمكررة، ثم تُطَبَّع قيم الاستغلال باستخدام أسلوب Min-Max. تُحسب معاملات التطبيع اعتماداً على مجموعة التدريب

فقط، ثم تُطبّق المعاملات نفسها على مجموعتي التحقق والاختبار؛ منعاً لتسرب المعلومات بين مجموعات البيانات. بعد ذلك، تُحوّل البيانات إلى نوافذ زمنية منزقة. نظراً إلى أن النموذج يستقبل قيم استغلال الشرائح الثلاث معاً، فإن كل عينة إدخال تتكون من مصفوفة تحتوي على قيم الشرائح خلال آخر 14 خطوة زمنية:

$$X(t) = \begin{bmatrix} U_C(t-13) & U_V(t-13) & U_{BE}(t-13) \\ U_C(t-12) & U_V(t-12) & U_{BE}(t-12) \\ \vdots & \vdots & \vdots \\ U_C(t) & U_V(t) & U_{BE}(t) \end{bmatrix} \in \mathbb{R}^{14 \times 3}$$

حيث تمثل U_C قيمة استغلال الشريحة الحرجة، وتمثل U_V قيمة استغلال شريحة الفيديو، بينما تمثل U_{BE} قيمة استغلال شريحة أفضل جهد. أما متجه القيم المستهدفة، فيتكون من قيم استغلال الشرائح الثلاث خلال الخطوة الزمنية التالية:

$$Y(t) = [U_C(t+1) \quad U_V(t+1) \quad U_{BE}(t+1)]$$

بما أن الفاصل الزمني بين العينات يساوي ثانية واحدة، فإن كل نافذة تمثل آخر 14 ثانية من سلوك أحمال الشرائح، وتُستخدم للتنبؤ بقيم الاستغلال للشرائح الثلاث خلال الثانية التالية. يسمح إدخال قيم الشرائح بصورة مشتركة للنموذج بتمثيل الأنماط الزمنية الخاصة بكل شريحة، إلى جانب العلاقات المشتركة بين تغيرات أحمال الشرائح.

4-1-1 اختيار طول النافذة الزمنية

اختُبرت عدة أطوال للنافذة الزمنية، هي:

$$W \in \{8, 10, 12, 14, 16, 20, 30, 40\}$$

أظهرت نتائج مجموعة التحقق أن النافذة ذات الطول $W = 14$ حققت أفضل توازن بين دقة التنبؤ والكلفة الحسابية وسرعة الاستجابة. لم توفر النوافذ الأقصر سياقاً زمنياً كافياً لتمثيل تغيرات الحمل، بينما زادت النوافذ الأطول عدد الخطوات الزمنية المعالجة وزمن التدريب، دون تحقيق تحسن إضافي في الأداء، كما أظهرت استجابة أبطأ للتغيرات الحديثة في الحمل. وحققت النافذة ذات الطول 14 أقل قيمة لمتوسط مربع الخطأ (MSE) بين الأطوال المختبرة؛ لذلك اعتمدت في النموذج النهائي.

2-1-4 تقسيم البيانات

قُسمت البيانات زمنياً، مع المحافظة على ترتيب العينات، وفق النسب الآتية: 70% للتدريب، و15% للتحقق، و15% للاختبار. لم تُخلط العينات عشوائياً أثناء التقسيم أو التدريب، حفاظاً على البنية الزمنية للبيانات ومنعاً لانتقال معلومات من الفترات المستقبلية إلى الفترات المستخدمة في تدريب النموذج.

3-1-4 بنية نموذج LSTM

استُخدم نموذج LSTM متعدد المتغيرات ومتعدد المخرجات؛ إذ يستقبل نافذة زمنية بأبعاد (3، 14)، تمثل قيم استغلال الشرائح الثلاث خلال 14 خطوة زمنية متتالية، وينتج ثلاث قيم متوقعة تمثل أحمال الشرائح خلال الخطوة الزمنية التالية. يتكون نموذج التنبؤ من طبقتي LSTM متتاليتين، تتبعهما طبقة إخراج خطية. تحتوي الطبقة الأولى على 64 وحدة، مع تفعيل الخيار `return_sequences=True` لإعادة التسلسل كاملاً إلى طبقة LSTM التالية، بينما تحتوي الطبقة الثانية على 32 وحدة. تُطبق طبقة Dropout بنسبة 20% بعد كل طبقة LSTM، ثم تُستخدم طبقة Dense تحتوي على ثلاث وحدات لإنتاج قيمة الحمل المتوقعة لكل شريحة. يمكن تمثيل بنية النموذج كما يأتي:

$$\begin{aligned} \text{Input}(14, 3) &\rightarrow \text{LSTM}(64, \text{return_sequences} = \text{True}) \\ &\rightarrow \text{Dropout}(0.20) \rightarrow \text{LSTM}(32) \rightarrow \text{Dropout}(0.20) \\ &\rightarrow \text{Dense}(3) \end{aligned}$$

تستخلص طبقة LSTM الأولى الأنماط الزمنية لكل شريحة والعلاقات المشتركة بين تغيرات أحمال الشرائح الثلاث ضمن نافذة الإدخال، بينما تختزل الطبقة الثانية هذه الخصائص في تمثيل زمني أكثر تركيزاً قبل تمريره إلى طبقة الإخراج. تنتج طبقة الإخراج متجه التنبؤ الآتي:

$$\hat{L}(t+1) = [\hat{L}_C(t+1) \quad \hat{L}_V(t+1) \quad \hat{L}_{BE}(t+1)]$$

حيث تمثل $\hat{L}_C(t+1)$ قيمة الحمل المتوقع للشريحة الحرجة، وتمثل $\hat{L}_V(t+1)$ قيمة الحمل المتوقع لشريحة الفيديو، بينما تمثل $\hat{L}_{BE}(t+1)$ قيمة الحمل المتوقع لشريحة أفضل جهد. اعتمدت البنية

التنازلية من 64 إلى 32 وحدة لتحقيق توازن بين قدرة النموذج على تمثيل الأنماط الزمنية والعلاقات المشتركة بين الشرائح من جهة، والكلفة الحسابية واحتمال الإفراط في التخصيص من جهة أخرى.

4-1-4 إعدادات التدريب

دُرِبَ النموذج بحد أقصى قدره 150 عصراً تدريبياً، وبحجم دفعة يبلغ 32 عينة، باستخدام محسن Adam بمعدل تعلم قدره 0.001، ومتوسط مربع الخطأ MSE بوصفه دالة للخسارة. كما طُبِّقَت تقنية Dropout بنسبة 20%، واستُخدمت آلية Early Stopping لمراقبة قيمة val_loss، بقيمة Patience مقدارها 12 عصراً وحد أدنى للتحسن min_delta يساوي 10^{-4} ، مع تفعيل استعادة أفضل أوزان حققها النموذج. نظراً إلى الطبيعة الزمنية للبيانات، لم تُخلط العينات عشوائياً أثناء التدريب. اختير محسن Adam بمعدل تعلم مقداره 0.001، نظراً إلى قدرته على تكييف معدل تحديث الأوزان أثناء التدريب، فضلاً عن ملاعته لتدريب نماذج التعلم العميق. يمثل العدد 150 الحد الأقصى للعصور التدريبية، وليس عدداً ثابتاً يجب تنفيذه كاملاً؛ إذ تُوقف عملية التدريب إذا لم تنخفض خسارة التحقق val_loss بمقدار لا يقل عن 10^{-4} خلال 12 عصراً متتالياً. بعد توقف التدريب، تُستعاد أوزان النموذج الموافقة لأقل قيمة مسجلة لخسارة التحقق. استخدم متوسط مربع الخطأ (MSE) بوصفه دالة للخسارة. ونظراً إلى أن النموذج ينتج ثلاث قيم متوقعة تمثل أحمال الشرائح الثلاث، تُحسب دالة الخسارة على جميع العينات والمخرجات وفق العلاقة:

$$MSE = \frac{1}{nN} \sum_{k=1}^n \sum_{i=1}^N (y_{k,i} - \hat{y}_{k,i})^2$$

حيث يمثل n عدد العينات، ويمثل $N = 3$ عدد الشرائح، بينما تمثل $y_{k,i}$ القيمة الفعلية للشريحة i في العينة k ، وتمثل $\hat{y}_{k,i}$ القيمة المتنبأ بها. اختيرت MSE لأنها تمنح أخطاء التنبؤ الكبيرة وزناً أعلى، وهو أمر مهم في تخصيص الموارد؛ إذ قد يؤدي الخطأ الكبير في تقدير الحمل إلى تخصيص موارد غير كافية أو حجز موارد تفوق الحاجة الفعلية. مع ذلك، لا يقتصر تقييم النموذج على MSE، بل تُستخدم أيضاً قيمتا MAE و RMSE لتقديم تقييم أشمل وأكثر قابلية للتفسير حيث تُحسب هذه المؤشرات

للمنموذج ككل، إضافة إلى حسابها لكل شريحة على حدة؛ للتحقق من عدم إخفاء الأداء الضعيف لإحدى الشرائح خلف متوسط النتائج الكلي. بعد انتهاء التدريب، يُحفظ النموذج الذي حقق أقل قيمة لخسارة التحقق، إلى جانب معاملات التطبيق وطول النافذة وإعدادات النموذج، ثم يُنقل إلى بيئة التنفيذ ولا تُحدَّث أوزان النموذج خلال التشغيل الفعلي؛ إذ يقتصر دوره على الاستدلال باستخدام القياسات الواردة.

4-2 معمارية التنفيذ (Runtime Architecture)

تعمل معمارية التنفيذ ضمن حلقة تحكم دورية تبدأها وحدة إدارة الموارد في EnterpriseVisor مرة واحدة كل ثانية. تتكون من ثلاث وحدات وظيفية مترابطة وهي وحدة المراقبة وجمع القياسات، ووحدة التنبؤ والتنعيم، ووحدة التخصيص وتطبيق القرار. يتبادل EnterpriseVisor و Libera Hypervisor البيانات والقرارات باستخدام واجهات REST API ورسائل JSON.

4-2-1 وحدة المراقبة وجمع القياسات

في بداية كل دورة، يطلب EnterpriseVisor من Libera Hypervisor أحدث قياسات استغلال الموارد. يتولى Libera جمع قيم استغلال عرض النطاق الترددي وإحصاءات التدفقات وصفوف الانتظار من متحكم ONOS ومبدلات OVS، ثم يرسلها إلى EnterpriseVisor. تُجمع القياسات مرة واحدة كل ثانية بما يتوافق مع الدقة الزمنية للبيانات المستخدمة. تتضمن كل رسالة معرف الشريحة، والطابع الزمني، والرقم التسلسلي، وقيمة الاستغلال الحالية، والموارد المخصصة، وحالة الشريحة. يُستخدم الرقم التسلسلي للتحقق من ترتيب القياسات، وكشف الرسائل المكررة أو المتأخرة.

4-2-2 وحدة التنبؤ والتنعيم

تُضاف القياسات المستلمة إلى مخزن زمني يحتفظ بأخر 14 قياساً متتالياً للشرائح الثلاث. عند اكتمال النافذة الزمنية، تُطَبَّع

قيمها باستخدام معاملات التطبيع المحفوظة من مرحلة التدريب، ثم تُمرَّر مجتمعةً إلى نموذج LSTM للحصول على متجه التنبؤ الخام:

$$\hat{L}(t+1) = [\hat{L}_C(t+1), \hat{L}_V(t+1), \hat{L}_{BE}(t+1)]$$

حيث تمثل عناصر المتجه الأحمال الخام المتنبأ بها للشريحة C ، وشريحة الفيديو V ، وشريحة أفضل جهد BE ، خلال الثانية التالية. بعد ذلك، يُطبَّق التعقيم الأسّي على القيمة المتنبأ بها لكل شريحة وفق العلاقة المعتمدة:

$$L_i^S(t+1) = \lambda \hat{L}_i(t+1) + (1-\lambda)L_i^S(t)$$

حيث تمثل $\hat{L}_i(t+1)$ قيمة الحمل الخام المتنبأ بها للشريحة i خلال الثانية التالية، وتمثل $L_i^S(t)$ القيمة المنعّمة في دورة التنبؤ السابقة، بينما تمثل $L_i^S(t+1)$ القيمة الناتجة بعد تطبيق التعقيم في الدورة الحالية. تمثل λ وزن التنبؤ الخام الحالي، بينما يمثل $(1-\lambda)$ وزن القيمة المنعّمة السابقة وقد اعتمدت القيمة:

$$\lambda = 0.40$$

وفق نتائج معايرة معامل التعقيم المعروضة في قسم النتائج. وبذلك، تحصل القيمة الخام المتنبأ بها خلال الدورة الحالية على وزن مقداره 40%، في حين تحصل القيمة المنعّمة السابقة على وزن مقداره 60%

$$L_i^S(t+1) = 0.40\hat{L}_i(t+1) + 0.60L_i^S(t)$$

يهدف هذا الاختيار إلى الحد من انتقال التقلبات قصيرة المدى إلى قرارات تخصيص الموارد، مع المحافظة على قدرة النظام على الاستجابة للتغيرات الفعلية في الأحمال.

3-2-4 وحدة التخصيص وتطبيق القرار

تستخدم وحدة التخصيص القيم المتنبأ بها بعد التعقيم لتحديد الشرائح النشطة وحساب الحصص النسبية والموارد المخصصة لكل شريحة، وفق المعادلات الموضحة سابقاً. بعد حساب التخصيص، يرسل EnterpriseVisor القرار إلى Libera Hypervisor، متضمناً معرفاً فريداً وإصداراً متسلسلاً للقرار والموارد المطلوبة لكل شريحة. يحوّل Libera القرار إلى سياسات للتحكم بالموارد تُطبق على مبدلات OVS، ثم يعيد رسالة تؤكد نجاح التطبيق أو فشله. لا يُعد قرار التخصيص مطبقاً ما لم تصل

رسالة التأكيد، تجنباً لحدوث اختلاف بين الحالة المحسوبة في EnterpriseVisor والحالة المطبقة فعلياً في الشبكة. وبذلك، يبدأ تسلسل التنفيذ بجمع القياسات، ثم تحديث النافذة الزمنية وتنفيذ التنبؤ والتتبع، وينتهي بحساب التخصيص وتطبيقه والتحقق من نجاحه.

3-4 تبادل الرسائل بين المكونات

تتبادل مكونات النظام القياسات وقرارات التخصيص باستخدام واجهات REST API، وتُمثل محتويات الرسائل بصيغة JSON. تشمل الرسائل الرئيسية: طلب القياسات من EnterpriseVisor إلى Libera Hypervisor. استجابة القياسات من Libera Hypervisor إلى EnterpriseVisor. طلب تطبيق التخصيص من EnterpriseVisor إلى Libera Hypervisor. رسالة تأكيد نجاح تطبيق التخصيص أو فشله. رسائل الأخطاء المرتبطة بفشل الاتصال أو معالجة الطلب. أما استدعاء نموذج LSTM فينفذ داخلياً ضمن EnterpriseVisor، ولذلك لا يتطلب تبادل رسائل REST مستقلة. تتضمن كل رسالة معرفاً فريداً للطلب، والطابع الزمني، والرقم التسلسلي، وحالة التنفيذ، إضافة إلى معرف الشريحة عند ارتباط الرسالة بشريحة محددة. تتيح هذه الحقول تتبع دورة القرار، وكشف الرسائل المكررة، والتحقق من ترتيب القياسات.

4-4 معدل التحديث وزمن الاستجابة وحجم البيانات

تعمل حلقة المراقبة والتنبؤ بمعدل تحديث مقداره مرة واحدة كل ثانية، ويُشترط أن تُنجز عمليات جمع القياسات ومعالجتها والتنبؤ وحساب التخصيص وتطبيق القرار قبل بدء دورة التشغيل التالية. يُحسب زمن دورة القرار الكلي وفق العلاقة:

$$T_{cycle} = T_{collection} + T_{communication} + T_{preprocessing} + T_{inference} + T_{allocation} + T_{enforcement}$$

حيث يمثل $T_{collection}$ زمن جمع القياسات، و $T_{communication}$ زمن نقل الرسائل، و $T_{preprocessing}$ زمن إعداد نافذة الإدخال، و $T_{inference}$ زمن استدلال النموذج، و $T_{allocation}$ زمن حساب قرار التخصيص، و $T_{enforcement}$ زمن تطبيق القرار. تُعرض نتائج زمن التنفيذ الفعلية في قسم التقييم باستخدام المتوسط الحسابي والانحراف المعياري، مع تحديد المراحل الداخلة في القياس.

كما يُقاس حجم كل نوع من الرسائل بعد ترميزه بصيغة JSON ، ويُسجل متوسط حجم الرسائل والحد الأقصى لها لتقدير عبء الاتصال بين مكونات النظام.

5-4 معالجة التأخير وفقدان الرسائل

تستخدم المعمارية معرفات الطلبات والأرقام التسلسلية للتحقق من ترتيب الرسائل وكشف الرسائل المكررة أو المتأخرة. عند عدم وصول الاستجابة ضمن المهلة الزمنية المحددة، يُعاد إرسال الطلب إذا سمح الزمن المتبقي من دورة التشغيل بذلك. عند فقدان قياس منفرد، يُعوض باستخدام آخر قيمة صحيحة أو الاستيفاء بين القيم المتاحة، مع تسجيل عملية التعويض. أما عند فقدان عدة قياسات متتالية، فلا يُستدعى نموذج LSTM اعتماداً على نافذة غير مكتملة، ويُحتفظ بآخر تخصيص صالح إلى حين استعادة القياسات. إذا تأخر التنبؤ أو تعذر الحصول على نتيجة صالحة خلال دورة التشغيل، يستخدم النظام قيمة الاستغلال الحالية لاتخاذ قرار احتياطي. عند تعطل EnterpriseVisor أو انقطاع اتصاله مع Libera Hypervisor، يستمر Libera في تطبيق آخر تخصيص ناجح. وفي حال فشل تطبيق قرار جديد، يحتفظ Libera بالتخصيص السابق ويرسل رسالة خطأ، بما يمنع انتقال الشبكة إلى حالة تخصيص جزئية أو غير متسقة.

6-4 دورة عمل الإطار المقترح


يبين الشكل (1) المراحل الرئيسية لعمل الإطار المقترح، بدءاً من جمع القياسات والتنبؤ بالأحمال باستخدام LSTM ، مروراً بالتعظيم الأسّي وتخصيص الموارد ديناميكياً، وانتهاءً بتطبيق السياسات وتحديث جداول OVS ضمن حلقة تحكم مغلقة.



الشكل (1) دورة عمل الإطار المقترح

5- بيئة التنفيذ والمحاكاة

تم تنفيذ إطار العمل المقترح وفق معمارية موزعة تتكون من ثلاثة مخدمات افتراضية مترابطة وظيفياً بهدف الفصل بين عمليات التحليل والمراقبة والتنفيذ وتحسين كفاءة المعالجة والاستجابة الزمنية كما يوضح الشكل (2).



الشكل (2): معمارية التنفيذ

اعتمد توزيع مكونات النظام على ثلاثة مخدمات افتراضية بهدف الفصل بين وظائف التنبؤ واتخاذ القرار، وإدارة الشرائح وتطبيق سياسات الموارد، ومحاكاة الشبكة وتوليد الحركة المرورية. يساعد هذا الفصل على تقليل التداخل بين الأعباء الحسابية للمكونات وإتاحة قياس زمن الاتصال والتنفيذ بصورة مستقلة. لا يمثل استخدام ثلاثة مخدمات شرطاً أساسياً لعمل الإطار؛ إذ يمكن دمج المكونات في مخدم واحد في البيئات محدودة النطاق.

المخدم الأول (EnterpriseVisor): يتولى هذا المخدم تنفيذ نموذج LSTM المسؤول عن التنبؤ بالأحمال المستقبلية للشرائح الافتراضية، إضافة إلى تنفيذ آلية التنعيم الأسّي ومعالجة البيانات التشغيلية الواردة من الشبكة. كما يقوم بحساب الحصص النسبية للشرائح وتنفيذ آلية التخصيص الديناميكي للموارد اعتماداً على الأحمال المستقبلية المتوقعة. وتُرسل قرارات التخصيص الناتجة إلى Libera Hypervisor لتطبيقها على الشبكة.

المخدم الثاني (Libera Hypervisor): يتولى مخدم Libera إدارة الشرائح الافتراضية ومراقبة استهلاك الموارد، حيث يقوم بجمع القياسات التشغيلية من المتحكم المركزي ONOS ومبدلات Open

vSwitch وإرسالها إلى EnterpriseVisor. كما يستقبل قرارات التخصيص الناتجة ويقوم بتحويلها إلى سياسات تشغيلية وقيود موارد تطبق على الشرائح المختلفة.

المخدم الثالث (Mininet & ONOS): يمثل هذا المخدم بيئة الاختبار والتشغيل، ويضم محاكي Mininet ومبدلات Open vSwitch (OVS) ومتحكم ONOS المسؤول عن إدارة التدفقات وتطبيق سياسات الشبكة. كما يحتوي على مجموعة من المضيفات الافتراضية التي تمثل الشرائح الشبكية المختلفة وتستخدم لتوليد الأحمال المرورية واختبار أداء آلية التخصيص المقترحة. تتبادل هذه المكونات البيانات والقرارات بصورة آنية عبر واجهات REST APIs ورسائل JSON ضمن حلقة تشغيل مستمرة. تبدأ العملية بجمع بيانات استغلال الموارد، ثم إرسالها إلى نموذج التنبؤ، وبعد الحصول على الأحمال المستقبلية المتوقعة وتتبعها، يتم حساب الحصص النسبية للشرائح وتخصيص الموارد ديناميكياً وفق الاحتياجات المستقبلية المتوقعة، مما يتيح دعماً فعالاً للتخصيص الاستباقي للموارد وتحسين استغلالها في بيئات vSDN متعددة الشرائح.

1-5 مجموعة البيانات المستخدمة

يعتمد هذا البحث على مجموعة البيانات المستخدمة في دراسة [5] والتي تمثل سلسلة زمنية لاستهلاك عرض النطاق الترددي على مدار يوم كامل بدقة زمنية مقدارها ثانية واحدة، حيث:

$$t = 1, 2, \dots, 86400$$

ويمثل Ut قيمة استغلال عرض النطاق الترددي عند الزمن t . تم اختيار بداية اليوم عند الساعة 06:00 صباحاً بهدف محاكاة بداية النشاط الفعلي لحركة الشبكة، مما يسمح بتمثيل واقعي لدورات الاستخدام اليومية.

2-5 تصميم الشرائح الشبكية (Network Slicing)

اشتُقت من السلسلة الزمنية الأصلية ثلاث سلاسل زمنية تمثل أنماطاً مختلفة من حركة المرور، مع المحافظة على أن يكون مجموع أحمالها مساوياً للحمل الكلي:

$$U(t) = C(t) + V(t) + B(t)$$

حيث تمثل $C(t)$ حمل الشريحة الحرجة (Critical Slice)، وتمثل $V(t)$ حمل شريحة الفيديو (Video Slice)، بينما تمثل $B(t)$ حمل شريحة أفضل جهد (Best-Effort Slice). تمثل الشريحة

الدرجة الخدمات الحساسة للتأخير، بينما تمثل شريحة الفيديو التطبيقات ذات الاستهلاك المرتفع لعرض النطاق الترددي، وتمثل شريحة أفضل جهد التطبيقات ذات المتطلبات الزمنية الأقل صرامة. ولدت سلاسل الشرائح باستخدام معاملات اشتقاق مختلفة لإظهار خصائص الحمل الخاصة بكل نوع من الخدمات.

ويقصد بالعلاقة بين الشرائح أنها مشتقة من الحمل الكلي نفسه، وتشارك في السعة الفيزيائية المتاحة؛ ولذلك تؤثر زيادة الموارد المخصصة لإحدى الشرائح في مقدار الموارد المتبقية للشرائح الأخرى. أما عدد الشرائح، فقد استخدمت ثلاث شرائح في السيناريو الأساسي لتمثيل ثلاثة أنماط تشغيلية مختلفة، وتسهيل تحليل سلوك التخصيص لكل نمط على حدة. كما جرى تقييم قابلية التوسع في سيناريوهات إضافية بزيادة عدد الشرائح والعقد، وتُعرض نتائجها في قسم التقييم التجريبي.

5-5 توليد حركة المرور وجمع القياسات

تم استخدام أداة D-ITG (Distributed Internet Traffic Generator) لتوليد الأحمال المرورية وتمثيل أنماط استخدام الشرائح المختلفة داخل بيئة الاختبار [2]. تم تخصيص المضيف $h1$ لتمثيل الشريحة الدرجة، والمضيف $h2$ لتمثيل شريحة الفيديو، والمضيف $h3$ لتمثيل شريحة أفضل جهد بينما استخدم المضيف $h4$ كوجهة نهائية للتدفقات. لتوفير سلوك مروري واقعي، تم ضبط كل شريحة وفق خصائصها التشغيلية؛ إذ تولد الشريحة الدرجة تدفقات صغيرة ومنظمة منخفضة التأخير، بينما تولد شريحة الفيديو أحمالاً مرتفعة ومتغيرة تحاكي تطبيقات الفيديو، في حين تولد شريحة الأفضل جهد حركة مرور عامة تحاكي تطبيقات الويب ونقل الملفات. لتحليل أداء الإطار تحت ظروف تشغيل مختلفة، نُفذت ثلاثة سيناريوهات إضافية إلى جانب حالة الحمل الاعتيادي. تمثل السيناريو الأول في زيادة عدد العقد والتدفقات النشطة تدريجياً بهدف تقييم قابلية توسع الإطار وتأثير ذلك في زمن اتخاذ القرار. تضمن السيناريو الثاني توليد حركة مرور انفجارية (Burst Traffic) من خلال رفع معدل الإرسال بصورة مفاجئة ولمدة قصيرة، بهدف قياس قدرة النموذج على اكتشاف الطفرة وسرعة استجابة آلية التخصيص لها. أما السيناريو الثالث، فتمثل في زيادة الحمل خلال فترة زمنية محددة ثم إعادته إلى مستواه الأساسي، بهدف تقييم قدرة النظام على التكيف مع التغيرات المستمرة واستعادة حالة التشغيل

المستقرة بعد زوال الحمل المرتفع. تم جمع القياسات التشغيلية بصورة دورية من مبدلات OVS ومتحكم ONOS عبر Libera Hypervisor، وشملت قيم استغلال عرض النطاق الترددي وإحصائيات التدفقات وصفوف الانتظار، إضافة إلى مؤشرات الأداء مثل زمن التأخير (Delay) والتذبذب الزمني للحمز (Jitter) والإنتاجية (Throughput) ومعدل فقدان الحزم (Packet Loss). استُخدمت قيم استغلال الشرائح الثلاث بوصفها مدخلات مشتركة لنموذج LSTM متعدد المتغيرات ومتعدد المخرجات، بينما استُخدمت مؤشرات الأداء لتقييم دقة التخصيص الديناميكي للموارد، واستقرار قراراته، وجودة الخدمة في السيناريوهات المختبرة.

6- النتائج والمناقشة

يهدف هذا القسم إلى تقييم أداء الإطار المستخدم ضمن بيئة vSDN متعددة الشرائح، من خلال تحليل دقة التنبؤ بالأحمال، وكفاءة تخصيص الموارد، وأثر التنعيم الأسّي في استقرار قرارات التخصيص. تُقيّم دقة نموذج LSTM من خلال مقارنته بنموذج GRU باستخدام مؤشرات MSE و MAE و RMSE. في المقابل، يُقارن أداء آلية التخصيص بكل من التخصيص الثابت والإطار المرجعي DLVisor، كما يُقارن التخصيص المعتمد على تنبؤات LSTM الخام بالتخصيص المعتمد على التنبؤات المنعّمة، بهدف تحديد أثر التنعيم بصورة مستقلة. يشمل التقييم مؤشرات تخصيص الموارد واستغلالها، واستقرار قرارات التخصيص، وجودة الخدمة (QoS)، ومعدلات انتهاك اتفاقيات مستوى الخدمة (SLA)، وهدر الموارد، وزمن التنفيذ. كما يُقيّم أداء الإطار تحت ظروف تشغيل مختلفة، تشمل الحمل الاعتيادي، والحمل الانفجاري، والزيادة المؤقتة في الحمل.

6-1 مقارنة أداء نموذجي LSTM و GRU

تمت مقارنة نموذج LSTM بنموذج GRU متعدد المتغيرات ومتعدد المخرجات باستخدام مجموعة البيانات نفسها وتقسيم زمني موحد بنسبة 70% للتدريب، و 15% للتحقق، و 15% للاختبار، مع المحافظة على ترتيب العينات وعدم خلطها أثناء التدريب. استقبل كل نموذج نافذة زمنية بأبعاد (3، 14)، تمثل قيم استغلال الشرائح الثلاث خلال 14 ثانية متتالية، وأنتج ثلاث قيم متوقعة تمثل أحمال الشرائح خلال الثانية التالية. لضمان عدالة المقارنة، استُخدمت إعدادات تدريب موحدة؛ إذ تألف

كل نموذج من طبقتين متتاليتين تحتويان على 64 و 32 وحدة، مع تطبيق Dropout بنسبة 20%، واستخدام حجم دفعة مقداره 32 عينة، ومحسن Adam بمعدل تعلم 0.001، ومتوسط مربع الخطأ MSE بوصفه دالة للخسارة، وحد أقصى يبلغ 150 عصاراً تدريبياً. كما استُخدمت آلية Early Stopping بقيمة Patience مقدارها 12 عصاراً، مع استعادة أفضل الأوزان. اقتصر الاختلاف بين النموذجين على استبدال طبقات LSTM بطبقات GRU. قُيِّم أداء النموذجين باستخدام مؤشرات MSE و MAE و RMSE، ويوضح الجدول (2) نتائج المقارنة:

النموذج	MSE	MAE	RMSE
LSTM	0.0038	0.041	0.0616
GRU	0.0043	0.044	0.0656

الجدول (2): مقارنة دقة التنبؤ بين نموذجي LSTM و GRU

أظهرت النتائج أن نموذج LSTM حقق قيمة أقل لمؤشرات الخطأ مقارنةً بنموذج GRU؛ إذ بلغت قيمة MSE مقدار 0.0038 مقابل 0.0043، وبلغت قيمة MAE مقدار 0.041 مقابل 0.044، في حين بلغت قيمة RMSE مقدار 0.0616 مقابل 0.0656. وتشير هذه النتائج إلى أن نموذج LSTM قدم دقة تنبؤ أعلى ضمن البيانات المختبرة، مع بقاء الفروق بين النموذجين محدودة. وبناءً على ذلك، اعتمد نموذج LSTM في بقية تجارب تخصيص الموارد وتحليل أثر التنظيم الأسّي.

2-6 تحليل أثر طول النافذة الزمنية

أُجريت مجموعة من التجارب لدراسة أثر طول النافذة الزمنية في دقة التنبؤ، مع تثبيت بنية نموذج LSTM وإعدادات التدريب وتقسيم البيانات. شملت أطوال النوافذ المختبرة:

$$W \in \{8, 10, 12, 14, 16, 20, 30, 40\}$$

قُيِّم أداء النموذج عند كل طول باستخدام مؤشرات MSE و MAE و RMSE على مجموعة التحقق. يوضح الجدول (3) نتائج المقارنة بين أطوال النوافذ المختبرة.

طول النافذة	MSE	MAE	RMSE
-------------	-----	-----	------

8	0.0050	0.048	0.0707
10	0.0045	0.045	0.0671
12	0.0040	0.042	0.0632
14	0.0036	0.040	0.0600
16	0.0038	0.041	0.0616
20	0.0041	0.043	0.0640
30	0.0048	0.047	0.0693
40	0.0055	0.051	0.0742

الجدول (3): أثر طول النافذة الزمنية في دقة نموذج LSTM

أظهرت النتائج أن زيادة طول النافذة من 8 إلى 14 خطوة زمنية أدت إلى انخفاض تدريجي في مؤشرات خطأ التنبؤ، إذ حققت النافذة ذات الطول $W = 14$ أقل قيم لمؤشرات الخطأ، بقيمة MSE بلغت 0.0036، وقيمة MAE بلغت 0.040، وقيمة RMSE بلغت 0.0600. يشير ذلك إلى أن النافذة ذات الطول 14 وفرت سياقاً زمنياً كافياً لتمثيل تغيرات أحمال الشرائح. في المقابل، لم تؤد زيادة طول النافذة إلى أكثر من 14 خطوة إلى تحسن إضافي في دقة التنبؤ، بل ارتفعت مؤشرات الخطأ تدريجياً مع زيادة عدد الخطوات الزمنية المعالجة. يُعزى ذلك إلى إدخال قيم زمنية أقدم قد تكون أقل ارتباطاً بالحمل المتوقع خلال الثانية التالية. بناءً على النتائج المحققة ضمن الأطوال المختبرة، اعتمدت النافذة ذات الطول $W = 14$ في بقية التجارب.

3-6 معايرة معامل التنعيم الزمني (λ):

أُجريت سلسلة من التجارب لتحديد القيمة المناسبة لمعامل التنعيم الزمني (λ)، وذلك بالاعتماد على ثلاثة مؤشرات هي: متوسط الخطأ المطلق (MAE)، والانحراف المعياري للإشارة المنعّمة (σ)، والتأخر الزمني للاستجابة. لتحديد القيمة المثلى بدقة ومسح كامل مجال الاستجابة، تم اختبار قيم منفصلة للمعامل (λ) بخطوة متساوية قدرها (0.05) بدءاً من 0.10 وصولاً إلى 1.0، ومقارنة مؤشرات الأداء لكل قيمة على حدة كما هو موضح في الجدول (4). يتبين من المسح الشامل للقيم في الجدول (4)،


يتخذ منحني متوسط الخطأ المطلق (MAE) شكلاً قطعياً، حيث تتسبب القيم المنخفضة بتراكم الخطأ نتيجة البطء في الاستجابة (العطالة)، بينما تتسبب القيم المرتفعة برفع نسبة الخطأ نتيجة استجابة النظام للضجيج والتذبذبات اللحظية. تُشكل القيمة

($\lambda = 0.40$) القعر الرياضي لمنحني الخطأ، محققة أدنى قيمة لمتوسط الخطأ المطلق ($MAE = 3.12 Mbps$) وتأخراً زمنياً منخفضاً وعملياً (2.15 ثانية). بناءً على هذه النتائج التجريبية المفصلة، تم التبرير العلمي القاطع لاعتماد القيمة 0.40 في التقييم التجريبي الشامل لآلية التخصيص.

قيمة المعامل (λ)	التأخر الزمني للاستجابة [ثانية]	متوسط الخطأ المطلق [$Mbps$] (MAE)	الانحراف المعياري للإشارة (σ)
0.10	40.50	18.20	3.15
0.15	34.20	16.45	4.21
0.20	25.40	13.10	6.30
0.25	15.20	10.50	8.45
0.30	8.10	7.80	11.20
0.35	4.50	4.95	13.10
0.40	2.15	3.12	15.34
0.45	1.50	4.50	18.20
0.50	0.90	5.80	20.50
0.55	0.80	6.45	21.80
0.60	0.72	6.95	22.90

قيمة المعامل (λ)	التأخر الزمني للاستجابة [ثانية]	متوسط الخطأ المطلق [$Mbps$] (MAE)	الانحراف المعياري للإشارة (σ)
0.65	0.65	7.40	23.90
0.70	0.60	7.85	24.80
0.75	0.56	8.35	25.80
0.80	0.53	8.65	26.30
0.85	0.50	8.92	26.85
0.90	0.47	9.35	27.50
0.95	0.44	9.85	28.25
1.00	0.40	10.50	29.10

الجدول (4): مقارنة مؤشرات الأداء عند قيم تجريبية منفصلة لمعامل التنعيم (λ) بخطوة (0.05)



الشكل (3): مقارنة إشارات التنبؤ عند قيم مختلفة لمعامل التنعيم (λ)

يوضح الشكل (3) السلوك الهيكلي لإشارات التنبؤ المُنَمَّعة عند تعرض النظام لارتفاع مفاجئ وحاد في حركة المرور مقارنةً بالحمل الفعلي المرجعي (Actual Traffic / Ground Truth) المُمَثَّل بالخط المنقط وذلك عند ثلاث قيم مفصلية لمعامل التعيم الزمني (λ):

الاستجابة الخمولية ($\lambda = 0.15$) المنحنى الأزرق: تظهر الإشارة تأخراً زمنياً حاداً في الاستجابة (Severe Time Lag) فعند حدوث القفزة المفاجئة في الحمل عند الزمن ($t \approx 180$ s) ، يظهر المنحنى ببطء شديداً في التكيف، ولا يصل إلى مستوى الحمل الجديد إلا بعد مرور زمن طويل ($t \approx 300$ s) هذا التأخير يتسبب في نقص مؤقت في تخصيص الموارد وتدهور مؤشرات جودة الخدمة (QoS)

الاستجابة العصبية ($\lambda = 0.85$) المنحنى الأحمر: تستجيب الإشارة بسرعة للتغير المفاجئ في الحمل، لكنها تعاني من تذبذبات حادة ومستمرة (High Fluctuations) طوال فترة المحاكاة. يعود ذلك إلى سماح قيمة λ المرتفعة بمرور الضجيج والتغيرات اللحظية العشوائية الصادرة عن نموذج التنبؤ، مما يسبب إعادة تخصيص متكررة وغير مستقرة للموارد.

الاستجابة المتوازنة المثلى ($\lambda = 0.40$) المنحنى الأخضر: تُحقق هذه الإشارة الأداء الأمثل؛ حيث تتبع الارتفاع المفاجئ في حركة المرور بسرعة وبشكل لحظي تقريباً مع الحد الأدنى من التأخر الزمني، وفي الوقت ذاته تقوم بتعيم الإشارة والتخلص من الضجيج والتذبذبات الحادة.

2-6 التحليل الديناميكي والتقييم التجريبي لأداء خوارزميات إدارة الموارد:


يعرض هذا القسم نتائج التقييم التجريبي للنموذج المقترح مقارنةً بإطار [5] DLVisor وآلية التخصيص الثابت ضمن بيئة vSDN متعددة الشرائح. تركز المقارنة على كفاءة التخصيص الديناميكي للموارد، واستغلال الموارد، وجودة الخدمة (QoS)، واستقرار قرارات التخصيص، وتأثير التعيم الأسّي على أداء

النظام في ظل سيناريوهات تشغيل مختلفة. يعتمد التحليل على إحدى عشرة نافذة زمنية مجمعة تمتد من T0 إلى T10، ناتجة عن تجميع 600 عينة جُمعت بمعدل قراءة واحدة في الثانية خلال مدة اختبار مقدارها عشر دقائق. تُمثل هذه النوافذ عينات حركية ديناميكية تغطي مختلف سيناريوهات التشغيل، بدءاً من حالات الحمل المنخفض والمتوسط وصولاً إلى قمم الذروة المفاجئة (Traffic Bursts) والتقلبات الديناميكية في طلب المستخدمين بين الشرائح المختلفة، مما يضمن تقييم قدرة النظام على التكيف والاستقرار تحت مختلف حالات الحركة لتقليل تأثير التذبذبات قصيرة المدى وإبراز الاتجاهات العامة لأداء النظام، تم حساب المتوسط الحسابي لكل 60 عينة متتالية، مما أتاح مقارنة السلوك الكلي للخوارزميات المختلفة على مستوى الفترات الزمنية المجمعة. ولضمان الموثوقية الإحصائية للنتائج وقابلية إعادة الإنتاج، تم تنفيذ كل تجربة محاكاة عبر 10 تشغيلات مستقلة، مع تثبيت (Random Seed = 42) عبر بيئة المحاكاة ومكونات التنبؤ لضمان تكافؤ الظروف البيئية، واعتماد المتوسط الحسابي لجميع القراءات والمؤشرات الناتجة.

1-2-6 مقارنة تخصيص الموارد

يمثل تخصيص الموارد آلية توزيع عرض النطاق الترددي بين الشرائح الشبكية بما يضمن الاستفادة الفعالة من الموارد المتاحة والاستجابة للتغيرات المستمرة في الأحمال المرورية. يوضح الشكل (4) مقارنة أداء الخوارزمية المقترحة مع كل من DLVisor وآلية التخصيص الثابت عبر الفترات الزمنية المختلفة. تظهر النتائج أن التخصيص الثابت يحافظ على حصص ثابتة للشرائح بغض النظر عن تغير الأحمال، مما يحد من قدرته على التكيف مع الاحتياجات الفعلية للشبكة. أما DLVisor فيوفر استجابة ديناميكية للتغيرات المرورية، إلا أنه يُظهر تذبذباً ملحوظاً في الحصص المخصصة، ولا سيما في شريحة Best-Effort، نتيجة تأثير قرارات التخصيص بالتغيرات اللحظية في الأحمال. في المقابل، حقق النموذج المقترح توازناً أفضل بين سرعة الاستجابة للتغيرات المرورية واستقرار قرارات التخصيص، حيث حافظ على قيم أكثر انتظاماً للموارد المخصصة في الشرائح المختلفة مع تقليل التقلبات الحادة مقارنة بـ DLVisor ويُعزى ذلك إلى استخدام التنبؤ الاستباقي بالأحمال بالاعتماد على نموذج LSTM مدعوماً بآلية التنظيم الآسي، مما ساعد على تقليل تأثير التذبذبات قصيرة المدى وإنتاج قرارات تخصيص

أكثر استقراراً. تشير هذه النتائج إلى أن دمج التنبؤ بالأحمال المستقبلية مع التتبع الزمني يسهم في تحسين استقرار عملية التخصيص الديناميكي للموارد، ويؤدي إلى استغلال أكثر كفاءة للموارد المتاحة مقارنةً بآليات التخصيص التقليدية والتفاعلية.



الشكل(4): توزيع حصص تخصيص الموارد الكلي من T0 إلى T10 عبر الشرائح التشغيلية الثلاث

1-1-2-6 تحليل الأثر التفكيكي لسبب التحسين (Ablation Analysis)

لتحليل الأسباب التفصيلية والمباشرة التي تقف وراء الأداء المتفوق والمستقر للإطار المقترح مقارنةً بإطار DLV، تم إجراء تحليل تفكيكي عملي (Ablation Analysis) عبر منهجية عزل المكونات


التشغيلية (Component Isolation) تحت نفس ظروف المحاكاة وتثبيت ($Seed = 42$) شمل هذا التحليل تقييم ثلاثة سيناريوهات اختبارية لتحديد الدور المستقل لكل مكون في تتبع منحنيات الصعود والهبوط في أحمال الشرائح:

1. سيناريو عزل التنعيم اختبار LSTM فقط: عند إيقاف آلية التنعيم وتمرير مخرجات التنبؤ الخام لشبكة LSTM مباشرة للمتحكم، نجح النموذج في استباق اتجاهات الطلب العامة وتلافي التأخير الزمني، ولكنه أظهر تذبذباً حاداً واضطراباً في التخصيص عند القمم والقيعان اللحظية نتيجة الحساسية المفرطة للضجيج والتغيرات العشوائية عابرة المدى (Spikes & Drops).
 2. سيناريو عزل التنبؤ (اختبار التنعيم الأسّي فقط): عند تطبيق التنعيم الأسّي كخوارزمية تفاعلية على البيانات التاريخية دون تنبؤ مستقبلي، حقق النظام منحنى تخصيص ناعماً ومستقراً جداً، ولكنه عانى من فجوة تأخير زمني (Time Lag) ملحوظة عند حدوث موجات صعود مفاجئة في حركة المرور، مما أدى لبطء الاستجابة وارتفاع معدل انتهاكات مستوى الخدمة (SLA).
 3. النموذج المقترح الكامل تكامل LSTM مع التنعيم الأسّي بـ $\lambda = 0.40$ يحقق التكامل الوظيفي بين العمليتين؛ إذ يختص الـ LSTM باكتشاف أنماط الصعود والهبوط واستباق قمم الطلب الحقيقية قبل حدوثها لتلافي التأخير الزمني، بينما يعمل التنعيم الأسّي كمرشح (Filter) لكبح القمم والقيعان اللحظية العشوائية الناتجة عن الضجيج اللحظي.
- يُثبت هذا التحليل التفكيكي أن الاعتماد على التنبؤ العميق بمفرده كما في إطار (DLVisor) يجعل قرار التخصيص يتبع كل قمة وقاع لحظي بشكل حاد ومضطرب، في حين أن الاعتماد على التنعيم بمفرده يفترق للقدرة الاستباقية. وبناءً عليه، يُعد الدمج الموزون بين المكونين هو السبب المباشر في تحقيق التوازن المثالي بين سرعة الاستجابة واستقرار توزيع الموارد.

2-2-6 مقارنة استغلال الموارد:

يُعد معدل استغلال الموارد أحد أهم مؤشرات تقييم كفاءة الأنظمة الافتراضية، إذ يعكس نسبة الموارد المستهلكة فعلياً مقارنة بالسعات المحجوزة. يستعرض الشكل (5) التحليل الكمي المقارن لمعدلات

الاستغلال على المستوى الكلي للمنظومة تحت تأثير استراتيجيات التخصيص المختلفة؛ حيث يتبين أن نظام التخصيص الثابت يسجل أدنى مستويات كفاءة الاستغلال على مدار الفترات الزمنية كافة، ويعزى هذا الانخفاض هندسياً إلى اعتماد هذا التخصيص على آلية الحجز الثابت، مما يُبقي على ساعات غير مستغلة وهدر بنيوي مستمر في النطاق الترددي لعدم مرونة النظام في الاستجابة لمتغيرات الأحمال الفعلية. من ناحية أخرى، ينجح إطار عمل DLV في رفع كفاءة الاستغلال مقارنة بالنظام الثابت نتيجة لقدرته على التتبع الديناميكي لمتطلبات السعة، إلا أن منحنى الأداء الخاص به يعاني من تذبذبات حادة وتقلبات مستمرة. في المقابل، تحقق الخوارزمية المقترحة الأداء الأكثر استقراراً، حيث يسلك منحنى الاستغلال مساراً ناعماً ومتوازناً يقترب من حدود الاستهلاك الفعلي، تثبت هذه النتيجة نجاح الخوارزمية في تحقيق المواءمة الديناميكية الدقيقة بين الساعات المحجوزة والأحمال الحقيقية لكل فترة زمنية مجمعة، مما يضمن رفع إنتاجية الشبكة إلى الحد الأمثل، مع الحفاظ التام على الضمانات الحتمية المقررة في اتفاقيات مستوى الخدمة (SLAs).



الشكل (5): معدلات استغلال الموارد الفعلي الكلي من T0 إلى T10 عبر الشرائح التشغيلية الثلاث


3-2-6 التحقق عالي الدقة عند نافذة زمنية محددة (High-Resolution Case Study)

يهدف تقييم السلوك التشغيلي للنموذج المقترح والتحقق من فاعلية آلية التخصيص الديناميكي للموارد تحت تأثير التغيرات اللحظية في الأحمال المرورية، جرى تنفيذ تحليل عالي الدقة (High-Resolution Analysis) عند نقطة زمنية محددة وقد وقع الاختيار على النافذة الزمنية T5 باعتبارها تمثل حالة تشغيلية متوسطة ضمن النتائج السابقة، حيث تعبر عن متوسط القيم المجمعة خلال فترة مقدارها 60 ثانية. من خلال استخراج العينات الفرعية الستين التي تشكل هذه النافذة الزمنية، تمت

دراسة السلوك اللحظي لكل من النموذج المقترح وإطار العمل DLVisor وآلية التخصيص الثابت، وذلك بهدف تحليل تأثير التغيرات السريعة في الأحمال على قرارات التخصيص. ويتيح هذا النوع من التحليل إظهار الفروق بين الآليات المختلفة من حيث استقرار التخصيص وقدرتها على التكيف مع التغيرات المرورية قصيرة المدى، والتي قد لا تظهر بوضوح في النتائج الزمنية المجمعة.

6-2-3-1 تخصيص الموارد عالي الدقة (High-Resolution Resource Allocation)

يوضح الشكل (6) نسب تخصيص الموارد عبر العينات الفرعية اللحظية للشرائح الثلاث المختلفة خلال النافذة الزمنية T5




الشكل (6): تحليل عالي الدقة لنسب تخصيص الموارد عند النافذة الزمنية T5

عند تتبع سلوك منحني الشريحة الحرجة (Critical Slice)، يلاحظ اختلاف واضح بين أداء النموذج المقترح وإطار العمل DLVisor في الاستجابة للتغيرات اللحظية في الأحمال. إذ يُظهر DLVisor تقلبات متكررة في نسب التخصيص نتيجة تأثره بالتغيرات السريعة في حركة المرور، بينما يحافظ النموذج المقترح على مسار أكثر استقراراً بفضل دمج التنبؤ الاستباقي بالأحمال مع التعقيم الآسي، مما يقلل التغيرات الحادة في الموارد المخصصة. يظهر هذا الأثر بصورة أوضح في شريحة أفضل جهد حيث يسجل DLVisor تذبذبات ملحوظة في التخصيص، في حين يقدم النموذج المقترح توزيعاً أكثر سلاسة واستقراراً للموارد. تؤكد هذه النتائج أن دمج نموذج LSTM مع التعقيم الزمني يوفر آلية أكثر اتزاناً لتخصيص الموارد، تسهم في تحسين استقرار التخصيص وتقليل التذبذب التشغيلي مع المحافظة على القدرة على التكيف مع التغيرات المرورية الفعلية.

2-3-2-6 استغلال الموارد عالية الدقة (High-Resolution Resource Utilization)

يعرض الشكل (7) نسب استغلال الموارد عبر العينات الفرعية اللحظية، بما يعكس كفاءة التشغيل الفعلية للبنية التحتية الافتراضية خلال الفترة الزمنية المدروسة. وتشير النتائج إلى وجود ارتباط مباشر بين استقرار قرارات التخصيص وكفاءة استغلال الموارد. ففي الشريحة الحرجة (Critical Slice)، حقق النموذج المقترح مستويات استغلال أكثر انتظاماً واتساقاً مع الموارد المخصصة مقارنةً بـ DLVisor ، الذي أظهر تقلبات ملحوظة نتيجة التغيرات المتكررة في قرارات التخصيص. ويُعزى ذلك إلى اعتماد النموذج المقترح على التنبؤ الاستباقي بالأحمال باستخدام نموذج LSTM مدعوماً بالتعقيم الآسي، مما قلل من تأثير التذبذبات قصيرة المدى ورفع كفاءة استغلال الموارد. وتؤكد هذه النتائج قدرة النموذج المقترح على تحقيق استغلال أكثر استقراراً وفعالية للموارد مقارنةً بالحلول التفاعلية التقليدية.



الشكل (7): تحليل عالي الدقة لنسب استغلال الموارد الفعلي عند النافذة الزمنية T5

4-2-6 جودة الخدمة (QoS)

لتقييم جودة الخدمة، تم الاعتماد على أربعة مؤشرات أساسية هي: زمن التأخير (Delay) والإنتاجية (Throughput) ومعدل فقدان الحزم (Packet Loss) والتذبذب الزمني للحزم (Jitter). لضمان إمكانية المقارنة بين هذه المؤشرات المختلفة، تم تطبيقها إلى المجال [0-1] باستخدام أسلوب Min-Max Normalization وفق العلاقة [18]:

$$X_n = \frac{X - X_{min}}{X_{max} - X_{min}}$$

وبالنسبة للمؤشرات التي تمثل القيم المنخفضة فيها أداء أفضل، مثل Delay و Packet Loss و Jitter، تم تطبيق التطبيع العكسي بحيث تشير القيم الأعلى إلى مستوى أفضل من جودة الخدمة. نظراً لاختلاف متطلبات الشرائح الشبكية، تم اعتماد أوزان تشغيلية مختلفة تعكس أهمية كل مؤشر بالنسبة لكل شريحة [16].

الشريحة الحرجة (Critical Slice)

تركز هذه الشريحة على الاعتمادية وزمن الاستجابة المنخفض، لذلك مُنحت مؤشرات التأخير وفقدان الحزم والتذبذب الزمني أوزاناً أعلى مقارنة بالإنتاجية:

$$QoS_{crit} = 0.35D_n + 0.30PL_n + 0.20J_n + 0.15Th_n$$

شريحة الفيديو (Video Slice)

تعتمد جودة الخدمة في هذه الشريحة بصورة أساسية على استقرار تدفق البيانات وتوافر عرض النطاق الترددي، لذلك مُنحت الإنتاجية والتذبذب الزمني أوزاناً أعلى:

$$QoS_{vid} = 0.15D_n + 0.20PL_n + 0.25J_n + 0.40Th_n$$

شريحة أفضل جهد (Best-Effort Slice)

لا تمتلك هذه الشريحة متطلبات صارمة فيما يتعلق بزمان التأخير أو الاعتمادية، لذلك تم اعتماد متوسط حسابي متساوٍ لجميع المؤشرات:

$$QoS_{be} = \frac{D_n + PL_n + J_n + Th_n}{4}$$

6-2-4-1 تحليل نتائج جودة الخدمة

يوضح الجدول (5) مقارنة أداء جودة الخدمة (QoS) بين الإطار المقترح و DLVisor وآلية التخصيص الثابت. أظهرت النتائج تفوق النموذج المقترح في جميع الشرائح الشبكية نتيجة اعتماده على التنبؤ الاستباقي بالأحمال باستخدام نموذج LSTM مدعوماً بالتنعيم الأسّي، مما ساهم في تحسين زمن التأخير والإنتاجية ومعدل فقدان الحزم والتذبذب الزمني للحزم. انعكس ذلك إيجاباً على قيم QoS الكلية ورفع كفاءة التخصيص الديناميكي للموارد مقارنةً بالحلول المرجعية.

الشريحة الافتراضية	الخوارزمية المقترحة	إطار عمل DLV	التخصيص الثابت
الشريحة الحرجة	0.88	0.84	0.66
الشريحة الفيديوية	0.84	0.78	0.60
شريحة أفضل جهد	0.74	0.67	0.53

الجدول (5): مقارنة لمؤشرات جودة الخدمة (QoS) للشرائح المختلفة

6-2-5 انتهاكات اتفاقيات مستوى الخدمة:

سُجل الانتهاك عند إخفاق أحد مؤشرات الأداء الرئيسة في تحقيق الحد المرجعي المحدد للشريحة، سواء تعلق ذلك بزمان التأخير أو الإنتاجية أو فقدان الحزم أو التذبذب الزمني للحزم. تم حساب نسبة الانتهاكات وفق العلاقة:

$$X_{SLA} = \frac{N_{violated}}{N_{total}} \times 100$$

حيث يمثل $N_{violated}$ عدد العينات التي تجاوزت متطلبات SLA، بينما يمثل N_{total} العدد الكلي للعينات خلال التجربة.

وتم تحديد حدود SLA بما يتوافق مع طبيعة كل شريحة، حيث فُرضت متطلبات أكثر صرامة على الشريحة الحرجة فيما يتعلق بالتأخير وفقدان الحزم والتذبذب الزمني، في حين ركزت متطلبات شريحة الفيديو على الإنتاجية واستقرار تدفق البيانات، بينما استُخدمت عتبات أكثر مرونة لشريحة أفضل جهد مع المحافظة على حد أدنى مقبول من جودة الخدمة واستمرارية التشغيل.

يوضح الجدول (6) معدلات الانتهاك المسجلة لكل من الإطار المقترح و DLVisor وآلية التخصيص الثابت، مما يسمح بتقييم قدرة كل آلية على المحافظة على متطلبات SLA في ظل ظروف التشغيل المختلفة.

الشريحة الافتراضية	الخوارزمية المقترحة	إطار عمل DLV	التخصيص الثابت
الشريحة الحرجة	5%	10%	18%
الشريحة الفيديوية	8%	12%	20%
شريحة أفضل جهد	12%	19%	27%

الجدول (6) مقارنة معدلات انتهاك اتفاقية مستوى الخدمة للشرائح المختلفة

أظهرت النتائج تفوق النموذج المقترح وفق مؤشرات التقييم المستخدمة في الحد من انتهاكات اتفاقيات مستوى الخدمة (SLA) عبر جميع الشرائح الشبكية مقارنةً بـ DLVisor وآلية التخصيص الثابت. تؤكد

هذه النتائج وجود ارتباط مباشر بين انخفاض معدلات الانتهاك وارتفاع قيم جودة الخدمة (QoS)، مما يعكس كفاءة أكبر في إدارة الموارد وتخصيصها بصورة ديناميكية.

6-2-6 إهدار الموارد:

يمثل هدر الموارد مقدار السعة المخصصة غير المستخدمة فعلياً من قبل الشرائح الشبكية، ويُستخدم لتقييم كفاءة آلية التخصيص. وتم حساب الهدر لكل شريحة وفق العلاقة:

$$W_i(t) = R_i(t) - U_i(t)$$

حيث تمثل $R_i(t)$ المخصصة، و $U_i(t)$ الموارد المستخدمة فعلياً.

أظهرت النتائج المبينة في الجدول (7) أن النموذج المقترح حقق أدنى معدلات هدر للموارد في الشريحة الحرجة وشريحة الفيديو مقارنة بـ DLVisor وآلية التخصيص الثابت. بلغ الهدر 8% و 7% على التوالي، مقابل 13% و 9% في DLVisor، و 18% و 14% في التخصيص الثابت. تشير هذه النتائج إلى قدرة النموذج المقترح على تحقيق موازنة أفضل بين الموارد المخصصة والطلب الفعلي مما أسهم في تحسين كفاءة استغلال الموارد وتقليل الساعات غير المستخدمة. أما في شريحة أفضل جهد فقد سجل النموذج المقترح معدل هدر بلغ 4% مقابل 3% في DLVisor و 9% في التخصيص الثابت. على الرغم من أن DLVisor حقق معدل هدر أقل في هذه الشريحة، فإن ذلك يُعزى جزئياً إلى توجيه نسبة أكبر من الموارد نحو الشرائح الأعلى طلباً، الأمر الذي يزيد احتمالية تعرض شريحة أفضل جهد لحالات حرمان من الموارد وانخفاض مستوى الخدمة المقدم لها. في المقابل، اعتمد الإطار المقترح حداً أدنى مضموناً من الموارد لهذه الشريحة بهدف المحافظة على استمرارية الخدمة وتقليل معدلات انتهاك اتفاقيات مستوى الخدمة، مما أدى إلى زيادة طفيفة في الهدر مقابل تحسين جودة الخدمة واستقرارها.

تؤكد هذه النتائج أن تحقيق أقل قيمة لهدر الموارد لا يمثل بالضرورة أفضل أداء تشغيلي، بل إن تحقيق توازن بين كفاءة الاستغلال والمحافظة على مستوى الخدمة يعد عاملاً أساسياً في تقييم فعالية آليات التخصيص الديناميكي للموارد.

الشريحة الافتراضية	الخوارزمية المقترحة	DLV إطار عمل	التخصيص الثابت
الشريحة الحرجة	8%	13%	18%
الشريحة الفيديوية	7%	9%	14%
شريحة أفضل جهد	4%	3%	9%

الجدول (7): نسب إهدار الموارد للشرائح الثلاثة

6-2-7 التحسين النسبي (Relative Improvement)

لقياس مقدار التحسن الذي حققه الإطار المقترحة مقارنةً بالنماذج المرجعية، تم استخدام معادلة التحسين النسبي التالية [6]:

$$Improvement(\%) = \left(\frac{W_{old} - W_{new}}{W_{old}} \right) \times 100$$

أظهرت النتائج انخفاضاً في هدر الموارد بنسبة 38.46% و 22.22% مقارنةً بـ DLVisor في الشريحة الحرجة وشريحة الفيديو على التوالي. أما في شريحة أفضل جهد فقد ارتفع الهدر بصورة طفيفة من 3% في DLVisor إلى 4% في الإطار المقترح، ويُعزى ذلك إلى تخصيص حد أدنى مضمون من الموارد للمحافظة على استمرارية الخدمة.

كما حقق النموذج المقترح معدلات تحسن بلغت 55.56% و 50.00% و 55.56% مقارنةً بآلية التخصيص الثابت في الشرائح الحرجة والفيديو وأفضل جهد على التوالي. تشير هذه النتائج إلى قدرة النموذج المقترح على تحسين كفاءة استغلال الموارد وتحقيق توازن أفضل بين تقليل الهدر والمحافظة على استقرار الأداء مقارنةً بالحلول المرجعية.

6-2-8 التعقيد الحسابي

تم تقييم التعقيد الحسابي وزمن التنفيذ لكل من التخصيص الثابت و DLVisor والإطار المقترح ضمن نفس بيئة التشغيل وتحت ظروف اختبار موحدة، وذلك بهدف قياس العبء الحسابي اللازم لاتخاذ قرار التخصيص.

التخصيص الثابت (Static Allocation)

يعتمد التخصيص الثابت على نسب موارد محددة مسبقاً دون إجراء أي عمليات مراقبة أو تنبؤ أو إعادة تخصيص أثناء التشغيل، لذلك يكون تعقيده الحسابي:

$$T(S) = O(1)$$

وعلى الرغم من انخفاض كلفته الحسابية، فإنه يفتقر إلى القدرة على التكيف مع تغيرات الاحمال الشبكية.

الإطار المرجعي (DLVisor)

يعتمد DLVisor على تصنيف الشرائح وتنفيذ عمليات حسابية متكررة تتعلق بالعرض والطلب وحل دالة التكلفة، مما يزيد العبء الحسابي مع زيادة عدد الشرائح والموارد:

$$O(nmh + m)$$

وبإهمال الحدود الأقل تأثيراً تصبح:

$$O(nmh)$$

حيث تمثل n عدد الخطوات الزمنية، و m عدد الشرائح المزودة للموارد، و h عدد الشرائح الطالبة للموارد.

الإطار المقترح

يعتمد الإطار المقترح على نموذج LSTM مدرب مسبقاً، لذلك تقتصر عملية التنبؤ أثناء التشغيل على مرحلة الاستدلال (Inference)، والتي يمكن تمثيلها كما يلي:

$$O(1)$$

أما عمليات جمع القياسات وتطبيق التنعيم الأسّي وحساب الحصص النسبية للشرائح وتخصيص الموارد فتتطلب المرور مرة واحدة فقط على جميع الشرائح:

$$T(S) = O(S)$$

حيث تمثل S عدد الشرائح الافتراضية.

يحقق هذا النهج نمواً خطياً قابلاً للتوسع مع زيادة عدد الشرائح، مما يجعله مناسباً للتطبيق في البيئات ذات متطلبات التشغيل في الزمن الحقيقي.

1-8-2-6 نتائج زمن التنفيذ

تم قياس زمن التنفيذ الكامل لدورة اتخاذ القرار بعد تكرار كل تجربة 100 مرة وحساب المتوسط الحسابي. أظهرت النتائج أن التخصيص الثابت حقق أقل زمن تنفيذ:

$$T_{Static} = 0.8 \text{ ms}$$

بينما سجل DLVisor:

$$T_{DLVisor} = 15.8 \text{ ms}$$

في حين بلغ زمن تنفيذ الإطار المقترح:

$$T_{Proposed} = 4.8 \text{ ms}$$

على الرغم من تفوق التخصيص الثابت زمنياً، فإنه لا يوفر أي قدرة على التكيف الديناميكي مع تغير الأحمال. أما بالمقارنة مع DLVisor ، فقد حقق النظام المقترح انخفاضاً في زمن التنفيذ بنسبة:

$$Improvement = \frac{15.8 - 4.8}{15.8} \times 100 = 69.62\%$$

مما يدل على قدرة النموذج المقترح على تقديم تخصيص استباقي للموارد مع عبء حسابي أقل وزمن استجابة أسرع مقارنةً بالإطار المرجعي.

2-8-2-6 تقييم القابلية للتوسع في حالات الشرائح المتعددة (Scalability Analysis)

يهدف إثبات التوافق بين التحليل النظري لمعادلات التعقيد الحسابي والنتائج العملية للأنظمة، تم إجراء سيناريو محاكاة تقييمي لقياس قدرة الخوارزميات على التوسع (Scalability) عند زيادة عدد الشرائح الشبكية النشطة (S). تم تنويع عدد الشرائح ضمن النطاق $S \in \{3,6,9,12\}$ شريحة مع تثبيت باقي ظروف المحاكاة والبذرة العشوائية ($Seed = 42$).

يُمثل هذا النطاق توزيعاً متوازناً وواقعياً لحركة المرور عبر تقسيم الشرائح بالتساوي بين ثلاث فئات تشغيلية رئيسية تختلف في متطلبات مستوى الخدمة (SLA):

1. الشرائح الحرجة (Critical Slices) التي تتطلب تأخيراً منخفضاً جداً وموثوقية عالية.

2. شرائح الفيديو (Video Slices) التي تتطلب نطاقاً ترددياً مرتفعاً وسعة تدفق عالية.
 3. شرائح أفضل جهد (Best-Effort Slices) التي تتعامل مع حركة المرور المرنة دون ضمانات صارمة للنطاق الترددي.
- يوضح الجدول (8) مقارنة متوسط زمن التنفيذ العملي مقاساً بـ ms اللازم لاتخاذ قرار التخصيص في الدورة التشغيلية الواحدة مع تزايد عدد الشرائح:

عدد الشرائح	نمط التوزيع الفئوي للشرائح	إطار DLVisor ($O(S^2)$)	النموذج المقترح ($O(S)$)	التخصيص الثابت
3 شرائح	1 درجة / 1 فيديو / 1 أفضل جهد	15.80	4.82	0.12
6 شرائح	2 درجة / 2 فيديو / 2 أفضل جهد	22.10	5.90	0.12
9 شرائح	3 درجة / 3 فيديو / 3 أفضل جهد	33.50	6.98	0.12
12 شريحة	4 درجة / 4 فيديو / 4 أفضل جهد	48.30	8.15	0.13

الجدول (8) مقارنة زمن التنفيذ [ms] عند التوسع في عدد الشرائح الشبكية (S)

يُستنتج من تحليل نتائج الجدول (8) ما يلي:

1. النمو الخطي واستقرار النموذج المقترح: يحافظ النموذج المقترح على معدل نمو خطي بطيء ومستقر لزمن التنفيذ بفضل تعقيده الحسابي الخطي ($O(S)$)، المكون من كلفة استدلال ثابتة لنموذج الـ LSTM تساوي $O(1)$ وكلفة تنعيم وتوزيع خطية $O(S)$. حيث يرتفع زمن اتخاذ القرار ببطء من 4.82 ms عند 3 شرائح، ليصل إلى 8.15 ms فقط عند 12 شريحة. يعزى ذلك إلى أن زمن تهيئة الاستدلال الثابت ($T_{base} \approx 3.74$ ms) يُمثل الكلفة الأكبر، بينما لا تتعدى الزيادة الحسابية لكل شريحة إضافية سوى 0.36 ms ≈ بغض النظر عن طبيعة الفئة، مما يضمن الاستجابة السريعة للشرائح الحرجة ضمن حلقة التحكم.

2. التزايد المتسارع لإطار DLVisor: أظهر إطار DLVisor نمواً متسارعاً يعكس طبيعة التقيد التربيعي ($O(S^2)$) الناتج عن حساب علاقات التداخل والعرض والطلب بين مختلف فئات الشرائح المزودة والطلبية ($O(nmh)$)، حيث قفز الزمن من 15.80 ms عند 3 شرائح ليصل إلى 48.30 ms عند 12 شريحة.

9-2-6 حساسية النظام لخطأ التنبؤ وتعديل التغذية الراجعة

منهجية الاختبار: جرى تقييم قدرة الإطار المقترح على استيعاب الانحرافات العشوائية في مخرجات نموذج LSTM عبر حقن ضوضاء غاوسية إضافية (Additive White Gaussian Noise – AWGN) بمقادير تدريجية ترفع نسبة خطأ التنبؤ (RMSE) بمقدار ($\pm 10\%$, $\pm 20\%$, $\pm 30\%$) لتقييم أثر الانحراف في قيمة الطلب المتنبأ به.

• الآلية الدفاعية المستندة للدالة الرياضية: تعتمد مرونة النظام أمام انحراف قيمة الطلب المتنبأ به على الموازنة الرياضية المدمجة في دالة حساب الأوزان:

○ الضبط بالقيم الحرجية لـ SLA: يضمن الحد المعتمد على أولوية الشريحة ومعامل حساسيتها ($\alpha_1 \cdot P_1$) بقاء الوزن المحسوب W_{S1} أعلى من القيمة الحرجية، مما يمنع انخفاض النطاق الترددي لشريحة البيانات الحرجة S_1 دون حد الضمان الأدنى (10 Mbps) حتى لو انخفضت القيمة المتنبأ بها نتيجة خطأ التنبؤ.

○ التعديل بالتغذية الراجعة اللحظية: يتدخل المتغير C_i (مستوى الازدحام المقاس لحظياً) لتقليص الفجوة الناجمة عن خطأ قيمة الطلب المتنبأ به في دورة التحديث التالية مباشرة ($\Delta t = 2 \text{ s}$).

• النتائج والتحليل:

○ عند انحراف قيمة تنبؤ الطلب حتى نسبة: $\pm 20\%$ حافظت الشريحة الحرجة S_1 على حد التأخير الصارم (10 ms) مع إنتاجية أدنى 10 Mbps وفقد رزم 0.1%؛ نظراً لكون الجبر الحسابي للمقدار ($\alpha_1 \cdot P_1$) يحظر هبوط الوزن المخصص دون الحد الحرج.

○ حماية الشريحة المرئية وشريحة الجهود الأفضل: حافظت شريحة البث المرئي S_2 على استقرار تدفقها فوق عتبة 50 Mbps وتأخير أقل من 50 ms. تم امتصاص الفروق المروية بتعديل

حصة شريحة الجهود الأفضل S_3 كدون الهبوط عن حدها الأدنى (5 Mbps) لضمان عدم حدوث ظاهرة مجاعة الموارد (Resource Starvation)، مع إبقاء تأخيرها ضمن الحد المسموح (150 ms) وفقد رزم أقل من 0.5%.

○ عند حد الانحراف الحرج (+30%): هيمن المتغير C_i على حسابات المعادلة ليفرض التخصيص بناءً على الازدحام الواقعي، مما حدّ من تأثير خطأ LSTM وحافظ على ثبات حلقة التحكم.

6-2-10 حساسية النظام للارتفاع المفاجئ في حمل المرور (Burst Traffic)

- منهجية الاختبار: جرى قياس استجابة حلقة التحكم عند تعريض الشبكة لحالات إشباع مروري مفاجئة تتجاوز السعة المخصصة للشرائح بنسب تراوحت بين 50% و 150% خلال فترات زمنية قصيرة (أقل من 1 s).
- الآلية الدفاعية: يعتمد النظام على استجابة ثنائية المستوى: عتادية عبر العزل الحسابي للموارد الذي يمنع تكس طوابير طلبات التوجيه (Packet-In) على متحكم ONOS، وبرمجية تستند إلى إعادة التخصيص الاستباقي عبر مسار الذكاء الاصطناعي.
- النتائج والتحليل: نجح مسار معالجة الذكاء الاصطناعي في إعادة الاستقرار وحوكمة النطاق الترددي خلال دورتين تشغيليتين فقط ($\Delta t \approx 4$ s) وخلال ثواني الاستجابة الأربع الأولى (الفترة الانتقالية)، حافظ المشرف (Libera Hypervisor) على العزل المنطقي الصارم للشريحة الحرجة S_1 ؛ فلم تسجل أي ارتفاع في زمن التأخير عن عتبة 10 ms أو تراجع في إنتاجيتها دون 10 Mbps، رغم وصول الحمل في شريحة البث المرئي S_2 وشريحة الجهود الأفضل S_3 إلى مرحلة الإشباع المفرط والتجاوز الحاد (150%).

6-2-11 مبررات استبعاد النماذج المعقدة (DRL و Transformers) من الحل المقترح

على الرغم من التفوق والانتشار الواسع لنماذج التعلم المعزز العميق (DRL) ونماذج المحولات (Transformers) في أدبيات البحث العلمي وقدرتها العالية على معالجة البيانات الديناميكية والسلاسل

الزمنية، إلا أنه تم استبعادها من التصميم التشغيلي الأساسي للحل المقترح واقتصار استخدامها بعضها كمرجع قياسي للمقارنة، وذلك للاعتبارات التقنية والتشغيلية التالية:

1- أسباب استبعاد نماذج التعلم المعزز العميق (DRL)

انفجار فضاء الحالات والأفعال (State-Action Space Explosion) يتسع فضاء البحث في خوارزميات DRL بشكل حاد مع تزايد عدد الشرائح الشبكية وتنوع فئاتها (الشرائح الحرجة، شرائح الفيديو، وشرائح أفضل جهد)، مما يؤدي إلى زيادة تصاعدية كبيرة في زمن التنفيذ تتجاوز القيود الصارمة لزمن استجابة متحكم الـ SDN بالزمن الحقيقي (Real-Time Control Loop)

- مخاطر مرحلة الاستكشاف وانتهاك SLA: تعتمد نماذج DRL على آلية الاستكشاف والاستغلال مما قد يدفع الخوارزمية لاتخاذ قرارات عشوائية أو غير مثالية أثناء التشغيل. يُشكل هذا السلوك خطورة عالية على الشرائح الحرجة التي تقتضي ضمانات صارمة للتأخير والموثوقية لا تحتمل أي تذبذب.

2- أسباب استبعاد نماذج المحولات (Transformers)

- التعقيد الحسابي لآلية الانتباه الذاتي (Self-Attention Complexity): يعتمد محرك الانتباه الذاتي في المحولات على تعقيد حسابي وتريعي يتزايد مع طول السلسلة الزمنية لمدخلات التنبؤ ($O(L^2)$) ، مما يسبب استهلاكاً عالياً للذاكرة وزيادة ملحوظة في زمن الاستدلال (Inference Latency)
- العبء العتادي وضخامة المعلومات : تطلب نماذج Transformer حجماً ضخماً من المعلومات وعمليات ضرب مصفوفات كثيفة تتطلب وجود تسريع عتادي متقدم كـ GPUs، وهو ما يتنافى مع متطلبات متحكمات الـ SDN أو العقد الطرفية (Edge Nodes) التي تتطلب نماذج خفيفة الوزن تعمل على معالجات قياسية.
- الحاجة المفرطة لبيانات التدريب: تقتصر المحولات إلى الانحياز الاستقرائي المدمج (Inductive Bias) الموجود في الشبكات العودية، مما يجعلها عرضة للإفراط في التكيف (Overfitting) عند تدريبها على سلاسل زمنية قصيرة لحركة مرور الشرائح.

بناءً على ما تقدم، يُحقق التوجه المقترح الذي يجمع بين تنبؤ LSTM خفيف الوزن والتتعيم الأسّي ذي الكفاءة الخطية $O(S)$ التوازن المثالي المطلوب؛ فهو يضمن الاستجابة الاستباقية والدقة العالية، مع الحفاظ على سرعة خاطفة لاتخاذ القرار دون إجهاد البنية التحتية لمتحكم الشبكة.

7- الخلاصة و الآفاق المستقبلية:

قدمت هذه الدراسة إطاراً استباقياً لتحسين كفاءة التخصيص الديناميكي للموارد في بيئات الشبكات الافتراضية المعرفة بالبرمجيات متعددة الشرائح (vSDN)، يعتمد على التنبؤ بالأحمال المستقبلية باستخدام نموذج الذاكرة طويلة قصيرة المدى (LSTM) مدعوماً بآلية التتعيم الأسّي. استُخدمت الأحمال المتوقعة في توجيه عملية تخصيص الموارد بصورة ديناميكية، بهدف تحسين استغلال الموارد وتعزيز استقرار قرارات التخصيص مع المحافظة على تعقيد حسابي منخفض ملائم لتطبيقات الزمن الحقيقي. أظهرت النتائج أن النموذج المقترح حقق تحسناً في جودة الخدمة (QoS) وكفاءة استغلال الموارد مقارنةً بكل من DLVisor وآلية التخصيص الثابت، كما ساهم في خفض معدلات انتهاك اتفاقيات مستوى الخدمة وتقليل هدر الموارد. كذلك بينت النتائج أن استخدام التتعيم الأسّي أدى إلى الحد من التذبذبات قصيرة المدى وتحسين استقرار عملية التخصيص، مما انعكس إيجاباً على الأداء التشغيلي العام للنظام. أظهر التحليل الحسابي أن آلية التخصيص المقترحة تحقق تعقيداً خطياً $O(S)$ ، مع زمن تنفيذ أقل من النظام المرجعي، الأمر الذي يجعلها مناسبة للتطبيق في البيئات الديناميكية متعددة الشرائح ذات متطلبات الاستجابة السريعة.

يمكن مستقبلاً توسيع هذا العمل من خلال دراسة نماذج تنبؤية أكثر تقدماً، مثل Transformers والنماذج الهجينة، وتقييم أداء الإطار المقترح ضمن بيئات شبكات الجيل السادس (6G) والحوسبة الطرفية (MEC). كما يمكن دراسة آليات تخصيص تكيفية تأخذ في الحسبان الخصائص المتغيرة لحركة المرور وتدعم مستويات أعلى من الاستقرار والكفاءة في إدارة الموارد.

قائمة المراجع

1. Alhatim, A. M., & Jalal, J. K. (2026). Investigation of software-defined networking (SDN) to enhance Wi-Fi networks in university campus. *Journal of Communications Software and Systems*, 22(1), 17–28. <https://doi.org/10.24138/jcomss-2025-0079>
2. Avallone, S., Guadagno, S., Emma, D., Pescape, A., & Ventre, G. (2004). D-ITG distributed Internet traffic generator. In *Proceedings of the First International Conference on the Quantitative Evaluation of Systems (QEST 2004)*. IEEE. <https://doi.org/10.1109/QEST.2004.1348045>
3. Blenk, A., Basta, M., Reisslein, M., & Kellerer, W. (2016). Survey on network virtualization hypervisors for software defined networking. *IEEE Communications Surveys & Tutorials*, 18(1), 655–685. <https://doi.org/10.1109/COMST.2015.2489183>
4. Cárdenas, A., Sigcha, L., & Mosahebfard, M. (2026). Predictive network slicing resource orchestration: A VNF approach. *Future Internet*, 18(3), Article 149. <https://doi.org/10.3390/fi18030149>
5. Hassan, M. K., Ariffin, S. H. S., Syed-Yusof, S. K., Ghazali, N. E., Khairi, M. E. A., Mohammed, K. S., & Hamdan, M. (2023). DLVisor: Dynamic learning hypervisor for software defined network. *IEEE Access*, 11, 43440–43455. <https://doi.org/10.1109/ACCESS.2023.3302266>
6. Jain, R. (1991). *The art of computer systems performance analysis: Techniques for experimental design, measurement, simulation, and modeling*. John Wiley & Sons.
7. Kadiyala, S., & Potluri, C. S. (2026). Multi-agent reinforcement learning framework for dynamic resource slicing and adaptive allocation in 6G network core. *ICTACT Journal on Communication Technology*, 17(1), 3815–3824. <https://doi.org/10.21917/ijct.2026.0564>
8. Lee, M.-W., Lin, Y.-S., & Chang, S.-Y. (2016). EnterpriseVisor: A dynamic resource management engine for software-defined enterprise networks. *IEEE Transactions on Emerging Topics in Computing*, 4(2), 179–186. <https://doi.org/10.1109/TETC.2015.2478757>
9. Ma, X., Zheng, B., Jiang, G., & Lui, L. (2023). Cellular network traffic prediction based on correlation ConvLSTM and self-attention network. *IEEE Communications Letters*, 27(7), 1909–1912. <https://doi.org/10.1109/LCOMM.2023.3275327>
10. Mao, K. (2026). Multi-agent reinforcement learning driven resource game optimization for network slicing in MEC-enabled HetNets. *Scientific Reports*, 16(1), Article 3231. <https://doi.org/10.1038/s41598-025-33190-5>
11. Ojaghi, B., Vilalta, R., & Muñoz, R. (2024). Intent-based network resource slicing in 6G. In *Proceedings of the International Conference on Network of the Future (NoF)* (pp. 1–6). IEEE. <https://doi.org/10.1109/NoF62948.2024.10741513>

12. Tamil Selvi, K., & Thamilselvan, R. (2022). An intelligent traffic prediction framework for 5G network using SDN and fusion learning. *Peer-to-Peer Networking and Applications*, 15(2), 751–767. <https://doi.org/10.1007/s12083-021-01282-x>
13. Wu, Z., Bravalheri, A., Ullauri, J. M. P., Nicolaescu, A. C., Wu, Y., & Simeonidou, D. (2025). DRL for network slicing: Resource efficiency optimisation under reconfiguration avoidance. In *2025 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS)* (pp. 1–6). IEEE. <https://doi.org/10.1109/INFOCOMWKSHPS65812.2025.1115284>
14. Yang, G., Yu, B.-Y., Jin, H., & Yoo, C. (2020). Libera for programmable network virtualization. *IEEE Communications Magazine*, 58(4), 38–44. <https://doi.org/10.1109/MCOM.001.1900290>
15. Bozakov, Z., & Papadimitriou, P. (2014). Towards a scalable software-defined network virtualization platform. In *2014 IEEE Network Operations and Management Symposium (NOMS)* (pp. 1–8). IEEE. <https://doi.org/10.1109/NOMS.2014.6838411>
16. Ali, J., Song, H. H., & Roh, B. H. (2025). An SDN-based framework for E2E QoS guarantee in Internet-of-Things devices. *IEEE Internet of Things Journal*, 12(1), 605–622. <https://doi.org/10.1109/JIOT.2024.3465609>
17. Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
18. Han, J., Kamber, M., & Pei, J. (2012). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann.