



多存取邊緣計算智慧分流

能源與環境研究所財團法人工業技術研究院退休研究員 / 呂錫民

關鍵字：分流、人工智慧、多存取、邊緣計算、機器學習

摘要

作為傳統遠程雲中心的補充，部署在移動用戶端附近區域的多存取邊緣計算（Multi-access Edge Computing, MEC）已視為5G異構網路的一項有前途技術。借助MEC，移動用戶可以有效地接觸計算資源。而且，可以通過分流（offloading）減輕核心網路擁塞。為了適應隨機且不斷變化的環境，增強人工智慧（AI）緣此引入MEC當中進行高效決策。最近的一些研究集中在MEC中的智慧分流上，以獲取其潛在的好處。因此，基於機器學習（Machine Learning, ML）的方法，包括強化學習（reinforcement learning）、監督/無監督學習（supervised/unsupervised learning）、深度學習（deep learning）、深度強化學習（deep reinforcement learning）等AI在MEC中的應用已成熱門話題。但是，MEC中的AI仍然需要解決許多技術挑戰。在本文中，介紹了MEC的基本概念和主要應用，並回顧使用各種基於ML的方法的現有基礎工作。此外，還討論了MEC中AI的一些潛在問

題，以供將來研究發展之用。

一、前言

在計算機科學中，分流（offloading）是將資源密集型計算工作轉移到外部平台（例如集群、網路或雲）的程序。由於設備硬體限制，如計算、存儲能量的有限，因此需要分流作業。其中資源密集型工作包括資料探索、病毒掃描、圖像處理、人工智慧、計算決策等。分流主要應用場合包括移動雲運算（mobile cloud computing）、邊緣計算（edge computing）和霧運算（fog computing）。

對於第五代（5G）[1]移動通信網路，無處不在的智慧雲計算是關鍵技術之一。但是有別於以往，在5G的MEC中，功能強大的雲中心通常部署在遠程移動用戶，因此需要通過多個中間節點傳輸大流量。結果，可能導致繁重的負荷、擁塞、延遲、能耗等，而這些都會削弱雲計算的優勢。因此，作為一種自然設計，提出了將計算資源從核心網路轉




圖 1 異構移動網路及其主要應用中的 MEC

移到邊緣的多存取邊緣計算 (MEC) [2]。

圖1說明了MEC在異構網路 (HetNets) [3]中的典型體系結構和主要應用。與遠程雲中心不同, MEC是邊緣網路中的分佈式網路體系結構。從MEC運營商的角度來看, 各種應用程式可以在更靠近移動用戶的邊緣網路上運行, 從而減少核心網路的擁塞。從移動用戶的角度來看, 資源受限的設備將從計算密集型和對延遲敏感的應用中解放出來, 以提高用戶的服務質量 (QoS)。首先, 可以通過上行鏈路通道將處理任務從計算受限

的單個設備分配給可用的資源豐富的MEC伺服器。接下來, 應分配相應的計算資源以在MEC端進行處理。處理完成後, 計算結果將通過下行信道反饋給移動用戶。此過程被廣泛稱為「分流」[3]。在啟用的MEC系統中, 例如啟用MEC的車輛網路和物聯網 (IoT), 應解決有關分流的以下關鍵問題:

- 移動用戶與MEC運營商之間的合作與競爭
- 用於通信和計算的資源匹配
- 朝向移動性、隨機性和異質性的實用機制設計



此外，由於分流是移動用戶與雲提供商之間的「連接」，因此它或多或少與MEC中的大多數關鍵問題相關（例如，分流決策、資源分配、移動性管理、內容緩存、綠能供應，安全和隱私[3]）。因此，分流自然在MEC中起著至關重要的作用，本文的其餘部分主要關注在MEC中的分流。

在實際的MEC系統中，由於影響因素是多維的，隨機不確定性加上時間變化，因此分流決策的優化是複雜的。並且，傳統方法（例如博弈論、優化理論）在這種複雜情況下遇到了障礙和局限。眾所周知，基於機器學習（ML）的人工智慧[4]可以從海量數據中提取有用信息、學習，並為隨機環境中的優化、預測和決策提供各種功能，例如使用數據分析服務特徵的採礦技術。一方面，人

工智慧通常依賴海量數據，這對於在MEC中應用的人工智慧是有好處的。另一方面，由於在人工智慧方面造成高昂的培訓和學習成本，MEC可以為智慧計算提供豐富的計算資源和低延遲的服務。通過引入智慧計算，MEC有望使邊緣網路實現自我優化和自適應，從而在MEC中形成一個增強智慧（AI）決策系統。具體而言，MEC中的AI不僅將人工智慧應用於設計規範或算法，還包括構建智慧MEC決策系統框架。

二、MEC 中分流的智慧方法

下面，簡要介紹一些主流的基於ML的分流方法。為了更好地理解ML方法，強化學習、監督學習和無監督學習、深度學習和深度強化學習的說明如圖2所示。




圖 2 機器學習方法的圖示：(a) 強化學習；(b) 有監督和無監督的學習；(c) 深度學習；(d) 深度強化學習



（一）分流中的強化學習

受行為心理學啟發的強化學習與決策者應如何通過與系統環境不斷交互選擇有關最佳化的動作[5]。強化學習的目標是為系統的每個狀態選擇一個動作，以便在長時間內最大化累積獎勵（延遲獎勵而不是立即獎勵）。強化學習適用於隨機和動態環境下的自動控制和決策。與其他類別機器學習不同，強化學習不能從數據中學習。相反，它必須學習自己的經驗。

馬爾可夫決策過程（MDP）：通常將強化學習環境表述為MDP，它提供了用於建模決策的數學框架。更具體地說，決策者在狀態 s_t 上選擇一個動作。然後狀態 s_t 將以轉移概率 $P(s_{t+1}|s_t, a_t)$ 進入下一個可能狀態，同時給出相應的獎勵 $r(s_t, a_t)$ 。隨著時間的推移，此過程將持續進行，決策者可以獲得一系列獎勵。顯然，這種系統的性能在很大程度上取決於人工製作的特徵質量（例如狀態、轉換概率）。

應用：根據移動用戶，分流可以節省他們的能量並提高計算能力，但會導致額外的傳輸和計算資源消耗。因此，應首先回答是否要分流。如果答案為「是」，則應選擇適當的MEC伺服器，並確定工作量以減輕負荷。在[6]中，考慮到用戶的隨機移動性和小雲的有限容量，Zhang等人使用MDP作為優化方法來研究分流策略，以實現長期穩定的分流/在地執行策略。文獻[6]中的MDP問題是基於動態規劃解決的，無需學習動作；但是，對於該問題，也可以採用諸如Q學習之類的強化學習算法。MDP的局限性在於，計算複雜

度將隨著狀態數量的增加而呈指數增長，從而導致「維數詛咒（curse of dimensionality）」問題。

Q學習：要解決MDP，應該完全了解系統模型（例如轉移概率）。但是，在實際網路中，尤其是在複雜的移動情況下，很難完全捕獲此信息。為了解決上述問題，Q學習[5]可以看作是一種搜索最優策略的反覆試驗方法。反覆試驗意味著決策者必須在未知環境中進行探索與開發之間的權衡。決策者更喜歡「利用」過去嘗試的具有最高累積獎勵的動作，但是它也必須「探索」更好的新動作，從而可能在將來產生更高的獎勵。經過充分的學習，決策者最終可以找到最優策略，其目標是學習最優動作值函數，以獲得給定狀態的最佳動作。與基於模型的MDP方法相比，Q學習是一種無需模型的在線學習方法，無需任何經驗環境知識。

應用：在動態MEC系統中，獲得關於網路環境的完美知識是不可行的。因此，Q學習可能適合信息量有限和動態環境下的決策，並且通常引入Q學習來設計在線和無模型學習方法。要在MEC中應用Q學習，第一步是確定動作、狀態和獎勵函數。然後，基於探索和開發，Q學習可以通過觀察給定系統狀態和動作的反饋來更新動作值函數。在[7]中，Xiao等人在動態環境中基於Q學習研究針對智慧攻擊的移動分流問題，其中一些系統參數（例如攻擊成本、分流增益和檢測精度）未知。[7]中的實驗結果發現，與隨機分流方案相比，使用Q學習的分流率 and 安全性分別提高了86%和6%。但是，由於尚未利用所有可能的狀態和動作，因此建議的策略



不能保證全面最優。此外，與MDP相似，由於「維數詛咒」，Q學習也並不適用於大型國有空間。

（二）分流中的有監督和無監督學習

監督學習[8]使用統計規則從標記的訓練數據中實現有效的推斷功能，該功能旨在學習一種分析模型，該模型可以根據輸入數據集預測相應的輸出結果。支持向量機（SVM）和支持向量回歸（SVR）是典型的監督學習算法，分別廣泛用於離散值分類和連續值回歸。相反，在無監督學習中輸入數據的標籤[9]是未知的，目標是找到隱藏在數據中的屬性和結構以實現預測和推斷功能。K均值（即，K-means）是最廣泛使用的無監督學習算法之一，它試圖將類別未知的數據劃分為幾個不相交的集群。這些方法相對簡單，在實際情況下易於採用，但是性能對訓練數據敏感。

應用：由於MEC中的服務需求隨時間變化而變化，因此使用分類和聚類方法針對不同服務功能自定義分流決策是有益的。除此之外，這些方法還可以用於估計或預測無線電參數、HetNets中的切換策略、無線網路中的異常檢測等。在[8]中，Khairy等人調查基於監督學習的智慧分流，以優化智慧手機的執行時間和能耗，其中通過測量不同上下文中的能耗來構建數據集。使用SVR，可以預測準確的應用程式執行時間和能耗，並且可以根據不同的服務功能做出計算分流決策。

同時，為了減輕干擾，在移動HetNets [9]中採用了基於K均值的上下文感知機制進

行小小區集群。[9]中的實驗結果發現，所提出的上下文感知預測可以指導移動用戶獲得穩定的無線鏈路。作為啟發之用，MEC伺服器的選擇和分流決策是由集群而不是單個決策來做出的，這樣可以有效且顯著減少大量參與者。但是，[8, 9]中的海量數據影響了預測的準確性，因此理論上很難給出性能界限，因此性能可能不穩定且不確定。此外，由於分類和聚類，移動用戶將更容易受到攻擊，因此應考慮隱私和安全性。

（三）分流中的深度學習

深度學習是一種基於多層神經網路的智慧（或特徵）學習方法，該方法允許計算模型從大量原始數據中自動提取預測或分類所需的特徵。如[10]所述，深度學習的關鍵優勢在於無需任何人工設置即可從數據中學習這些功能，這與依靠人工製作功能來進行強化學習不同。但是，深度學習被視為黑盒子。因此，由於沒有完全的理論分析，所以在實際訓練模型中需要訓練技巧和經驗。由於必須使用複雜的計算來訓練大量數據，因此自然而然地引入MEC可以提供可用的計算資源和原始數據。

應用：深度學習可以看作是解決包括故障和安全檢測、流量和行為預測等問題的理想工具。首先，MEC從移動網路中提取有用的功能，並且在離線模式下在MEC伺服器端訓練模型。訓練後的模型可以為即時環境中的識別和預測提供推理功能。因此，在MEC系統中使用深度學習產生對特徵的更好理解將有助於預測隨機變化，以減輕決策制定的優化。在Liu等的研究中[11]，將基於深度學



習的分類算法集成到基於邊緣計算的即時計算系統中。在邊緣設備（例如，用於醫療保健的可穿戴設備）中的預處理數據被傳輸到MEC伺服器。通過在整個網路中分配計算密集型任務的執行，可以在所提出的系統中使用卷積神經網路（CNN）進行更準確的數據分析。Liu等[11]所提出的識別方法可實現很高的檢測精度（95.2%）。但是，不可預測的訓練時間、較長的響應延遲和大量的標記數據是此問題上的主要挑戰。

（四）分流方面的深度強化學習

如上所述，深度學習可以通過學習高維原始數據來直接提取有用的函數。同時，傳統的強化學習需要人工製作的函數來學習最佳決策，而低維狀態空間則是必需的。為了學習現實世界中複雜環境下的最優控制和決策，Mnih等[12]提出了深度Q網路（DQN）作為典型的深度強化學習，它可以使用端到端直接從高維原始數據中學習。結束強化學習和深度學習。在DQN中，行動值函數由一個深度神經網路近似。另外，通過隨機採樣存儲經驗可以加速訓練過程的經驗重播機制，以更新深度神經網路參數。

應用：深度強化學習可以通過在線方法在未知系統中學習策略，以適用於快速變化的MEC系統。要在MEC中應用DQN，主要過程分為四個步驟：

1. 首先，運營商或控制器通過從邊緣網路的觀察收集原始數據，包括MEC伺服器上可用的計算資源、移動用戶的能量限制、無線信道狀況、拓撲結構等。

2. 其次，在更新操作值函數的同時，將過渡後的數據輸入DQN模型中以提取有用的特徵。
3. 然後，通過執行動作值函數作為反饋來反覆訓練和更新DQN模型。
4. 最後，DQN模型在某些條件下輸出用於分流的最佳決策。

在[13]中，He等人研究使用DQN進行互聯車輛網路中的資源分配，以實現基站關聯、內容緩存和分流策略。通過使用DQN近似和訓練動作值函數，可以獲得具有更好性能和更快訓練速度的最優策略。結合考慮了網路、緩存和分流功能後，建議的資源分配策略的性能比未結合考慮的性能提高了60%。但是，較大的離散狀態空間可能會導致更長的訓練時間。

三、優勢、局限和應用

在本章中，我們首先基於ML方法和傳統方法進行分流模擬。其次，對基於ML方法的主要特點、優勢、局限性和應用等作出總結。最後，我們討論學習方法的應用。

（一）機器學習與傳統方法相比

為了說明ML方法的優點和局限性，針對相同的分流問題，使用MDP、Q學習和凸優化（convex optimization）進行基本模擬。假設有任務的移動用戶在MEC伺服器的覆蓋範圍內隨機移動，並且全部或部分工作負荷可以通過無線網路傳輸到MEC伺服器。首先，



我們將MEC分流問題表述為MDP問題，以確定要分流的工作量，然後通過動態編程解決該問題。其次，作為典型ML方法，採用Q學習來確定針對同一問題的最佳策略。第三，針對此分流問題的凸優化也作為基準案例，因為它是在各種情況下廣泛使用的傳統方法。為了評估分流收益，將其公式化為效用函數，以減去分流成本和懲罰成本，其中效用函數是為了顯示分流收益（這是一種廣泛使用的非遞減對數函數），分流成本為由於傳輸和計算中的資源消耗所造成，而懲罰性成本是由於間歇性連接[6]而導致的分流失敗所引發（定義為分流失敗概率乘以分流工作負荷）。假設分流失敗概率的數學期望為0.1，相應的方差為0.025，MDP和Q學習中的折現因子為0.9（用於確定當前和未來獎勵的權重），藉此對動作值函數進行更新。為了顯示學習方法的性能，分別基於 1×10^4 和 5×10^4 學習時間（表示為N）執行Q學習。

如圖3(a)所示，與凸優化（通常使用分流失敗概率的數學期望作為決策指南）相比，MDP和Q學習在隨機情況下具有更高的收益。同時，我們還可以看到，學習次數越多，Q學習的收益就越高。具體來說，我們可以觀察到當N很小時，Q學習的性能不穩定，這是因為狀態空間隨著工作量的增加而呈指數增長。隨著學習時間的增加，Q學習有更多機會探索足夠的狀態以搜索最佳策略。因此，Q學習作為一種廣泛使用的ML方法，由於其學習能力適合於動態和隨機情況。此一AI特色套用在MEC分流解決分案上十分適合。

儘管已經提出了許多基於ML的方法來解決MEC分流問題，但是仍然存在一些挑戰。尤其是，數據收集的開銷、學習維數的詛咒以及決策的計算複雜性是基於ML的方法設計的主要障礙。如圖3(b)所示，MDP在對數規




圖 3 使用非學習和基於學習的方法進行分流時的系統收益和運行時間與總工作量的比較



表 1 MEC 分流中基於 ML 的方法的比較

類別	強化學習	監督 / 無監督學習	深度學習	深度強化學習
典型技術	MDP, Q 學習	SVM, SVR/K 均值	CNN	DQN
特點	- 從自己的經驗中學習 - 延遲獎勵	從標記或未標記的數據中學習	從原始數據中學習表示	直接從高維數據中學習控制策略
好處	沒有先驗知識的學習	易於快速部署	端到端學習功能	端到端強化學習
局限性	- 維數詛咒 - 探索與開發之間的權衡 - 人工製作的特徵	- 對數據敏感 - 依賴巨量數據 - 從理論上講很難限制性能	- 非常長的培訓時間 - 培訓技巧, 黑盒子 - 主要依靠大量的標籤數據	- 在較大的離散狀態空間中的訓練時間非常長 - 黑盒子
應用領域	自動控制和決策 間歇式小雲的通常策略 [6] 防止智慧攻擊的通常策略 [7]	分類和聚類 能耗和執行時間的預測 [8] 小小區聚類 [9]	檢測和預測 制定政策的認可系統 [11]	自動控制和決策 聯網車輛的資源分配策略 [13]

模下的運行時間隨著工作量的增加而呈指數增長。原因是較高的工作負荷將由於離散狀態而導致更大的狀態空間。此外, Q學習的更好性能需要更多的學習時間, 這也導致更多的計算資源消耗和更長的運行時間。

表1總結了用於MEC分流的ML方法的基本特徵、主要優點、局限性和典型應用。

(二) 機器學習與傳統方法另一相比

注意, ML方法和傳統方法在MEC系統中並不矛盾。相反, 它們兩者都可以很好地使用並且可以互補。傳統方法需要有關移動用戶模式和網路參數的經驗知識。在靜態或緩慢變化的環境中, 應首選傳統方法。但是, 在隨機且快速變化的移動網路中, 沒有或只有有限的經驗知識可以作為決策指南, 則應首選ML方法。而且, 在這樣的環境中訓練整個數據集在計算上是不可行的。另一方面, 有必要動態地適應新的模式。因此, 應設計

在線學習, 以便隨著時間的推移獲得有效且適應性強的MEC策略。為了在系統參數未知的情況下快速學習, Xu等在[14]中提出了一種新的基於決策後狀態的強化學習算法, 該算法可以「動態」學習動態工作負荷分流和邊緣伺服器配置的最佳策略。為了解決維數的詛咒, 一種在線學習算法利用離線模型迭代和在線強化學習的分解, 從而顯著提高了學習率和運行時性能。

綜上所述, 由於以下原因, MEC中各種約束下的分流問題需要動態的在線解決方案:

1. 由於分流、在地處理、新來者和超時離開, 移動用戶的剩餘工作量隨時間變化。
2. 由於其他移動用戶做出的分流決策, 目標MEC伺服器的可用帶寬或計算能力可能會隨時間變化。
3. 連接到目標MEC伺服器以進行分流的移動



用戶數可能會更改。

- 由於移動用戶移動性或移動網路重新配置，目標MEC伺服器可能會更改。

四、MEC 系統設計中的 AI：框架和挑戰

儘管已顯示出一些良好的性能，但在

MEC系統中使用傳統方法或ML方法的大多數現有作品僅關注特定的問題或目標，並沒有針對MEC系統進行概括和通用。為了說明一般的分流過程，圖4提出基於帶有反饋迴路的「觀察-決定-行動」[15] AI框架的MEC。該框架從下至上主要分為五層，根據服務需求和網路架構逐步引入AI能力，分別稱為觀察、分析、預測、策略和評估。




圖 4 MEC 分流中的 AI：帶有反饋迴路的觀察決策行為



觀察層：這是MEC中AI的基本功能。它連接到MEC系統，以從基礎結構層收集生成或接收的原始數據。為了快速提取有用的信息（例如，分流工作量、QoS要求、信道條件和拓撲），必須精確且有效的進行數據採集、存儲、清理和預處理以減少學習的複雜性。安全和隱私也是在這一層中應解決的重要問題，在該層中，應準確識別海量原始數據中的非法、不安全和惡意數據（例如，拒絕服務（DoS）攻擊）。提取的信息是分析層的輸入。

分析層：此層用於數據分析，其中可以基於來自觀察層的過濾數據來分析一些有用的功能。由於在MEC系統中靠近海量數據，因此在此層中應對實時推理功能（即分類和聚類功能）進行良好的預訓練，以為下一層提供指導。此外，由於某些服務需要較少的計算精度，因此應設計低複雜度的方法，以便在隨機環境中通過在線分析為MEC提供快速決策。

預測層：考慮到MEC中的隨機和多種情況，為了實現對分流的精確估計，該層旨在根據歷史經驗和來自前幾層的功能來預測未來的移動網路變化（例如，MEC伺服器負荷、流量和用戶移動性）。在這一層的協助下，可以在策略層做出有見地且有遠見的決策，以實現前瞻性規劃。

策略層：這對於智慧化MEC系統至關重要，MEC系統將根據分析的網路特徵和變化的趨勢為分流和其他目的做出決策。該層中的大多數工作主要集中於如何針對特定MEC分流問題建立模型和優化參數，因此很難在

常規MEC系統中進行擴展。實際上，當前的努力僅根據經驗選擇一種方法來單獨解決給定的問題。因此，我們認為關鍵的挑戰在於回答「如何」確定哪種模型適合「什麼」問題和場景，以及「何時」使用傳統或基於機器學習的方法。

評估層：遠程雲中心具有整個MEC系統的全面視野；因此，它適合長期培訓和學習全面策略。同時，在MEC和遠程中心之間的合作下，該層將從能耗、資源利用率、QoS等方面評估策略的有效性。因此，可以將評估結果反饋給MEC系統，以回答先前的分流決策是否合適、變化趨勢的預測是否準確、特徵和特性的分析是否準確、以及提取的數據是否有用。總之，這些層可以具有自適應和自我優化的學習能力，以迭代方式增強MEC系統。

此外，AI功能中的每一層都應與MEC系統的每一層正確配合。因此，未來的研究應仔細探討這些層之間的關係和相互作用。同時，每個層不能優化其自身的功能和輸出，因為還要考慮對下一層的影響。為此，如何將AI功能與MEC系統進行適當匹配，以及如何在不同AI層之間共同進行優化，將是未來的一個有趣話題。

五、結論

在本文中，我們簡要介紹了MEC中分流的概念以及潛在好處。我們已經說明了在MEC中使用AI的必要性，並討論了最新研究工作中基於ML的典型方法的基本思想。接下來，我們比較了ML方法和傳統方法的性能。



同時，說明了主要特徵、局限性和應用。儘管現有研究顯示了AI在MEC中的巨大優勢，但仍有一些潛在的研究主題。因此，我們展示了有關如何設計基於AI的MEC系統的初步想法，並討論了MEC中智慧分流的一些挑戰。

參考文獻

1. T.X. Tran et al., "Collaborative Mobile Edge Computing in 5G Networks: New Paradigms, Scenarios, and Challenges," *IEEE Commun. Mag.*, vol. 55, no. 4, pp. 54-61, Apr. 2017.
2. ETSI, "MEC in 5G Networks," white paper, no. 28, June 2018.
3. P. Mach and Z. Becvar, "Mobile Edge Computing: A Survey on Architecture and Computation Offloading," *IEEE Commun. Surveys & Tutorials*, vol. 19, no. 3, pp. 1628-56, Mar. 2017.
4. C. Jiang et al., "Machine Learning Paradigms for Next-Generation Wireless Networks," *IEEE Wireless Commun.*, vol. 24, no. 2, pp. 98-105, Apr. 2017.
5. R.S. Sutton and A.G. Barto, "Reinforcement Learning: An Introduction," *IEEE Trans. Neural Net.*, vol. 9, no. 5, pp. 1054-54, Sept. 1998.
6. Y. Zhang, D. Niyato, and P. Wang, "Offloading in Mobile Cloudlet Systems with Intermittent Connectivity," *IEEE Trans. Mobile Comp.*, vol. 14, no. 12, pp. 2516-29, Dec. 2015.
7. L. Xiao et al., "Mobile Offloading Game Against Smart Attacks," *Proc. IEEE INFOCOM Wksp.*, pp. 403-08, 2016.
8. A. Khairy, H.H. Ammar, and R. Bahgat, "Smartphone Energizer: Extending Smartphone's Battery Life with Smart Offloading," *Proc. IEEE IWCMC*, pp. 329-36, 2013.
9. M. Xiong and J. Cao, "A Clustering-Based Context-Aware Mechanism for IEEE 802.21 Media Independent Handover," *Proc. IEEE WCNC*, pp. 1569-74, 2013.
10. Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, vol. 521, pp. 436-44, May 2015.
11. C. Liu et al., "A New Deep Learning-Based Food Recognition System for Dietary Assessment on An Edge Computing Service Infrastructure," *IEEE Trans. Serv. Comp.*, vol. 11, no. 2, pp. 249-61, Mar. 2018.
12. V. Mnih et al., "Human-Level Control Through Deep Reinforcement Learning," *Nature*, vol. 518, no. 7540, pp. 529-33, 2015.
13. Y. He, N. Zhao, and H. Yin, "Integrated Networking, Caching and Computing for Connected Vehicles: A Deep Reinforcement Learning Approach," *IEEE Trans. Vehic. Tech.*, vol. 67, no. 1, pp. 44-55, Jan. 2018.
14. J. Xu, L. Chen, and S. Ren, "Online Learning for Offloading and Autoscaling in Energy Harvesting Mobile Edge Computing," *IEEE Trans. Cognitive Commun.*, vol. 3, no. 3, pp. 361-73, Sept. 2017.
15. ETSI, "Improved Operator Experience Through Experiential Networked Intelligence (ENI)," white paper, no. 22, Oct. 2017.