

令和 3 年 6 月 11 日現在

機関番号：13801

研究種目：基盤研究(B) (一般)

研究期間：2017～2020

課題番号：17H01730

研究課題名(和文) 深層強化学習を用いたモバイルデータ3Dオフローディングの研究

研究課題名(英文) Study on Mobile Data 3D Offloading using Deep Reinforcement Learning

研究代表者

峰野 博史 (Mineno, Hiroshi)

静岡大学・情報学部・教授

研究者番号：40359740

交付決定額(研究期間全体)：(直接経費) 14,300,000円

研究成果の概要(和文)：空間利用効率の最大化を目指すモバイルデータ3Dオフローディングの評価に関し、UEがどのような条件でどのようにデータ送信すれば、eNB負荷を適切に平滑化できるか、様々な条件設定のネットワークシミュレーションへ深層強化学習を適用した、Q学習に深層学習を適用したDQNを用いた送信レート制御モデルの構築と評価に加え、深層強化学習による効果的な通信制御手法の獲得に焦点を絞り5Gのネットワークスライシングを想定した研究を進めた。Ape-Xを用いた分散学習でモデルがスライスにネットワーク資源を割り当てるよう設計し、スライス数の変化に柔軟に対応可能なネットワーク資源割当てを深層強化学習可能なことを示した。

研究成果の学術的意義や社会的意義

様々な遅延耐性を持つコンテンツの特性を活かしたモバイル3Dオフローディング手法に対し、時間的、空間的局所性を考慮して空間利用効率の最大化を図る制御手法を深層強化学習によって獲得可能なことを示した。実機での適切な評価が規格的に困難かつ、解析モデルやネットワークシミュレーションによる評価では条件設定やモデル構築を現実に近いのが困難な情報ネットワーク研究に対し、深層強化学習適用の効果を検証した意義は大きい。シミュレータによって得られた強化学習結果を基に実機制御を行い、その実機での結果を基に深層学習を段階的に行うスパイラル学習法が今後ますます重要になると考える。

研究成果の概要(英文)：Regarding the evaluation of mobile data 3D offloading aiming at maximizing space utilization efficiency, under what conditions and how the UE should transmit data to appropriately smooth the eNB load, we evaluated applying deep reinforcement learning to network simulation with various condition settings. In addition to the evaluation of transmission rate control models using DQN, we proceeded with the research focusing on the acquisition of effective communication control methods for 5G network slicing management. Based on the design that allocate network resources to one slice by distributed learning using Ape-X, we confirmed it was possible to optimally allocate resources independently of the number of slices by changing the number of agents.

研究分野：情報ネットワーク

キーワード：モバイルネットワーク データオフローディング

1. 研究開始当初の背景

スマートフォン普及や、マルチメディアコンテンツ増加、IoT (Internet of Things)の急成長等に伴い、携帯電話網のトラフィックが増大している。携帯電話キャリアは、携帯基地局の増強や電波資源の有効活用、マイクロセル化だけでなく、WiFi スポット増設によって携帯電話基地局へのトラフィックをWiFi スポットへオフローディングし、個々の携帯基地局への負荷を低減させている。このようなWiFi スポットによるモバイルデータオフローディングは、先進国の都市部だけでなく、新興国を含め世界的に広がりを見せ始めている。現在のモバイルデータオフローディング手法は一定の効果をもたらしているものの、空間利用効率最大化という観点では以下のような改善余地が多分にあると言える。

(1) 時間的、空間的局所性

昨今のマイクロジオデータに代表される G 空間情報の分析から、携帯電話網のトラフィックは時間帯や地域で大きな局所性があり、時間的には夜間に、空間的には都市部でトラフィックが集中する特性を持つ。近年、基地局 eNB (evolved Node B) 負荷の時間的局所性を解消する UPCON (User Plane Congestion Management)[3GPP TR23.705, 2015]が提案されている。UPCON では、PCEF (Policy Charging Enforcement Function) サーバが eNB 負荷値を示す制御情報 RCI (RAN user plane Congestion Information) を用いて、UE (User Equipment) やアプリケーション毎の QoS 制御によって時間的局所性を解消する。一方、空間的局所性に対し、UE の接続先 eNB を動的に変更し各 eNB 負荷の平滑化を図る手法も提案されているが、具体的に有効な QoS 制御方法まで議論していないだけでなく、現実の無線通信規格の多様性や通信プロトコル、移動特性など複雑な条件まで考慮してこれら局所性に対し適切にオフローディングさせる研究はこれからである。

(2) モバイルデータのトラフィック特性

スマートフォンでの動画視聴などユーザに起因する通信に比べ、端末同士が自律的に通信する M2M では、通信速度の変動や遅延がユーザ体感品質に与える影響は小さい。また、定期撮影画像や動画をクラウドサーバへアップロードするライフログカメラやドライブレコーダ、クラウド上の地図データのローカル同期など、1日程度の遅延耐性を持つアプリケーションも存在し、トラフィックの中には遅延をある程度許容するデータ(遅延耐性データ)が存在するといえる。WiFi スポットは、携帯電話網に比べ高速に通信可能だが通信可能範囲は狭く、通信ノードの移動速度や WiFi スポットの混雑状況・電波状況によっては、WiFi スポットに接続しない方が安定通信できる場合や、そもそも近隣に WiFi スポットがなくオフローディングできない場合も多い。そこで、遅延耐性のあるモバイルデータに着目し、プライオリティを付けるなどして、多種多様なモバイルデータのトラフィック特性に応じた適切な通信路選択と送受信タイミングの制御を実現できれば、膨大な設備投資を抑えつつヘテロジニアスな通信路を併用した実効的なモバイルデータオフローディングが可能と考える。

2. 研究の目的

当研究グループがこれまで研究開発を進めてきた、時間的、空間的、通信路的な 3次元で空間利用効率を最大化させるモバイルデータ 3D オフローディング手法は、空間的オフローディング機能の評価が進み、ユーザが移動する評価シナリオで時間的・空間的オフローディングの特性評価を進めている。また、Android エミュレータと連携させた HiFEE による高精細評価と実機評価準備を進め、ネットワークシミュレータの生成する UE 移動や eNB 負荷変動に対し、MDOP における空間的・時間的オフローディングの適切な切替条件の詳細分析も可能となった。

しかし、本研究成果を実用に耐える成果へ繋げることを考えると、遅延耐性時間内にデータを送受信できるか否かは、UE トラフィックモデルや UE モビリティモデル、eNB 負荷モデル、トポロジモデルなど様々な複雑なシナリオ設定に大きく依存するだけでなく、同一 UE 内における MDOP 対応アプリと非対応アプリの混在、MDOP 対応アプリ間でも優先度の異なるデータ通信を行う場合など、多様な現実的な条件を想定した MDOP 詳細設計を進める必要があるのも事実である。これら複雑な条件を全て考慮した多数のシナリオで、MDOP のモバイルデータ 3D オフローディング手法を確立させるのは、典型的な組合せ最適化問題であり、実用的な時間で最適解を算出し、どのような条件でどのように各 UE が自律的に送受信レートを制御し、eNB 負荷を効果的に平滑化できるのか、適切な条件を見つけるのは人力では困難である。そこで、2016年3月に衝撃を与えた Alpha Go[Silver, Nature2016]等で採用された深層強化学習を参考に、どのような局面でどのように UE 群が自律的にデータ送受信タイミングを制御すれば eNB 負荷を効果的に平滑化できるか、深層強化学習の適用による解決を試みる。深層学習によって環境データ統合と特徴学習を実現し、送受信タイミングや送受信量の自動獲得を協調学習によって達成するというアプローチを情報ネットワーク研究に適用することで、シミュレーション上の経験で得られたスキルを分散学習して、各 UE が自律して状況に応じ適切な送受信レート制御できるオフローディング手法の獲得を目指す。単純シナリオから複雑シナリオへ順次展開し、将来的には HiFEE のような高精細エミュレーション環境での深層強化学習も想定され、実環境でも効果的なモバイルデータ 3D オフローディング手法の獲得達成を目指す。

3. 研究の方法

遅延耐性のあるモバイルデータ通信に対し、時間的、空間的、通信路的にデータの送受信タイミングを適切に自律協調制御することで、eNB 負荷を平滑化させるモバイルデータ 3D オフローディング手法の確立を目指す。様々な複雑シナリオが想定される組合せ最適化問題に対し、以下のステップで、深層学習と強化学習を組合わせた深層強化学習を情報ネットワーク研究開発に適用し、最適な UE 送受信制御手法の獲得と、段階的なスパイラル学習法への展開によって提案手法の有効性を実証する。

- i) モバイルデータ 3D オフローディング手法の詳細特性評価
- ii) 深層強化学習の適用による UE 送受信制御手法の獲得（発展）
- iii) 段階的スパイラル学習法で MDOP の実証評価

4. 研究成果

i) モバイルデータ 3D オフローディング手法の詳細特性評価

送信レート制御方法として、遅延耐性に着目し送信レート制御を行う MDOP の中でも、まずは時間的オフローディングに対して深層強化学習を適用した。図 1 に提案手法の通信フローを示す。送信レート制御モデルの構築は、Reinforcement Learning server (RLserver) が MDOPserver の集計するデータを基に、UE へ帯域を割り当てる優先度を学習し構築を行う。MDOP は対応するアプリケーションが生成するデータの遅延耐性に着目し、時間的・空間的・通信路的の 3 つの方法で送信レート制御を行い負荷分散する。時間的オフローディングでは、UE の持つ端末情報と eNB データ受信量を集計し、トラフィックが特定の時間帯に偏る特性（以下、時間的局所性）に着目しながら UE の送信レートを制御する。

図 1 に示すように、時間的オフローディングに深層強化学習を適用し、送信レート制御モデルを構築するため、まず MDOPserver が集計する UE の端末情報と eNB データ受信量を環境情報として RLserver へ送信する。次に、RLserver が環境情報から対象 UE へ帯域を割り当てる優先度を表す QoS レベルの導出を行う。最後に MDOPserver が QoS レベルを基に後述する送信レート制御を行って負荷分散する。送信レート制御の結果、eNB 負荷が制御目標値となる理想負荷に収束するよう学習を繰り返すことで、RLserver が UE の持つ端末情報と eNB の状態から帯域利用効率を最大化するために適切な送信レートを各 UE に割り当てる。

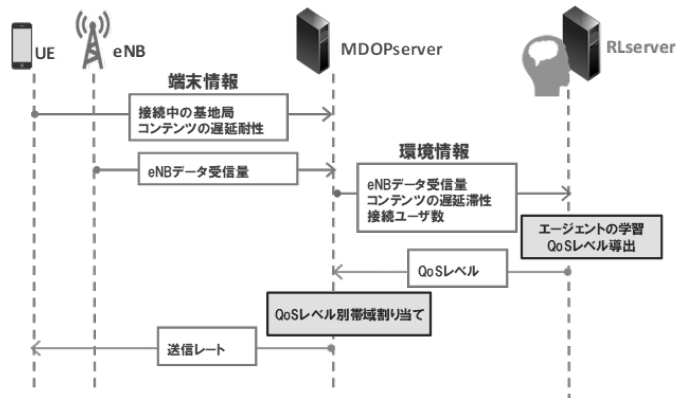



図 1 MDOP 通信の学習フロー

送信レート制御モデル構築時の学習方法として、まずは強化学習の一種である Q 学習に深層学習を適用した Double Deep Q-Network (DDQN) を用いた。DDQN は学習時に、学習環境のある時点の状況を表す状態 s で取りうる行動 a の選択と評価でそれぞれ異なるモデルを使用する学習方法である。Q 学習は状態 s における行動 a の価値を行動価値関数 $Q(s, a)$ として定量化し、 $Q(s, a)$ を最大化するように逐次更新することで行動の最適化を行った。ここで、深層強化学習の学習モデルとして Deep Q-network (DQN) が代表的な学習方法であるが、DQN は行動 a を選択するモデルと評価するモデルが同一であるため、行動 a を過大評価し精度が低下する課題が存在する。DDQN は行動選択と評価に異なるモデルを用いるので、行動 a の過大評価をすることなく学習が可能である。そこで、RLserver の学習には DDQN を採用し、送信レート制御モデルを構築することとした [Mochizuki, Sensors 2019]。

提案手法が帯域利用効率を向上させることを確認するため、MDOP の時間的オフローディングの中でも単純な送信レート制御手法（以下、既存手法）と提案手法をシミュレーションで比較評価した。まず、提案手法と既存手法の帯域利用効率を比較するため、UE の初期位置と移動経路が異



(a) 超過データ量削減率

(b) 送信量増加率

図 2 時間情報無モデルとの比較結果

なる評価シナリオ A~H を用意し、提案手法と既存手法をそれぞれ適用した場合の eNB 負荷変動から、帯域利用効率を比較評価した。次に時間経過に伴い経時的に変化するトラフィックに対して送信レート制御モデル構築時に特徴量として時間情報を考慮する有効性について評価した。

評価には LTE 環境を忠実に再現できるネットワークシミュレータ Scenargie を用い、学習時に用いるシナリオは評価シナリオと異なるものとした。通信環境モデルについては、3GPP が推奨している通信環境モデルに基づき設定した。様々な検証を行った結果、図 2 に示すように時間情報有モデルが時間情報無モデルに比べ超過データ量を削減し、送信量を概ね増加することが確認できた。特にシナリオ B では、80%超過データ量を削減した。時間有モデルは時間情報として遅延耐性残余時間を特徴量を持つことで、遅延耐性残余時間から QoS レベルの割り当てが可能となり、コンテンツの遅延耐性切れの発生回数が削減し理想負荷から超過するデータ量を減少させたと考える。送信量に関しては、シナリオ F で最大 0.8%増加、シナリオ C で 0.5%減少し、時間情報の有無によって全体の送信量に変化は見られなかった。総送信量を増加させるためには、時間情報以外の特徴量選択や帯域割当方法の更なる検討が必要だが、時間経過に伴い経時的に変化するデータに対して、時間情報を特徴量として考慮することの有効性を確認できた。

ii) 深層強化学習の適用による UE 送受信制御手法の獲得 (発展)

深層強化学習の適用によって更なる発展的な研究開発を進めた。特に eNB の負荷分散に加えて、遅延を許容できないデータの通信を行う UE の QoS を高めるよう、遅延耐性を考慮したハンドオーバー制御について検討した[安孫子, 信学論 2019]。コンテンツの遅延耐性時間はアプリケーションごとに大きく異なるが検討を容易にするため、遅延耐性の異なるコンテンツを持つスマートフォンなどを遅延耐性のない UE (以降, NontolerantUE) とし、遅延を許容できるデータ通信の想定される IoT 機器などを遅延耐性のある UE (以降, TolerantUE) とした。また、今後はますます普及が期待される、IoT 機器で通信されるセンシングデータや画像の収集など想定し、アプリケーションを制御対象とした。

本ハンドオーバー手法では eNB の負荷分散のためにハンドオーバーを行い eNB 負荷の平準化を行う。ハンドオーバーが多発するとハンドオーバーを行った UE の QoS の低下を引き起こしてしまう。そこで、QoS の低下を抑制するために既存のハンドオーバー制御を拡張し、図 3 に示すように遅延耐性別に UE のカバレッジを調整する手法を検討した。TolerantUE に対しては低負荷な eNB のカバレッジを広げ、積極的に低負荷な eNB へ負荷分散のためのハンドオーバーを行う。一方で NontolerantUE は、TolerantUE と比べ低負荷な eNB のカバレッジを狭め、負荷分散のためのハンドオーバーを消極的に行う。以上のように、NontolerantUE と TolerantUE の混在した環境に対して遅延耐性を考慮したハンドオーバーを行うことで、eNB 間の負荷分散を行いつつ、負荷分散で空いた帯域で NontolerantUE の QoS 向上を図った。




図 3 ハンドオーバー制御の評価モデル

比較評価では、eNB のパラメータを調整した環境や遅延耐性を考慮した負荷分散手法と比較を行い、提案手法を用いることで、既存手法と比較して eNB の負荷分散ができ、NontolerantUE の QoS を向上できることを評価した。eNB パラメータ調整のみの w/o 0 と w/ 0 は、マクロセルの eNB 総受信量が約 9.5GBytes となった。一方で、提案手法では、マクロセルの eNB 総受信量が約 7GBytes と eNB 負荷の削減を確認できる。さらに、スモールセルの総受信量は、提案手法で約 7GBytes と他の手法と比べて約 4GBytes 以上向上しており、提案手法を用いることで eNB 間の負荷を分散できることを確認した。

iii) 段階的スパイラル学習法で MDOP の実証評価

より実効的な MDOP の実証評価に向けて、深層強化学習による効果的な通信制御手法の獲得に焦点を絞り研究開発を深めた。特に、データレート的高速化、End to End (E2E) レイテンシの削減、信頼性の向上、大規模なデバイス接続など、第 4 世代モバイル通信 (4G) での課題を改善する第 5 世代モバイル通信 (5G) を想定し、限りある無線リソースの使用効率を低下させることなくスライス要件を満たすリソース制御について、DRL (Deep Reinforcement Learning) に分散学習を適用した Ape-X を用いた無線リソース割り当て手法を検討した。

RL (Reinforcement Learning) では、環境を観察し行動するため、学習の速度は環境に依存する。環境が単純な場合、学習速度は速くなる。一方で、大規模なシミュレーターまたは実環境が対象の場合、学習速度は遅くなる。そこで、学習を並列化して速度を改善することが重要である。さらに、現実の問題を対象とする場合、一般的に環境内には複数のエージェントが存在する。この観点から、複数のエージェントを制御できるように、エージェントを並列化する必要がある。エージェントを並列化して学習を高速化する手法は分散学習と呼ばれ、Ape-X は DQN に分散学習を適用し Experience Replay を改善した手法である。

RAN (Radio Access Network) には、ネットワークリソースとして RB (Resource Block) を

持つ。RAN スライシングでは、スライス数に関係なく、最小の RB 割り当てでスライス要件を満たす手法が必要である。そこで、Ape-X を用いた柔軟な RB 割り当て手法を研究した。既存手法ではエージェントが制御するスライス数が固定されていたため、学習時と制御時でスライス数が異なる場合、モデルの再学習が必要であった。そのため、提案手法では1つのエージェントが1つのスライスに RB を割り当て、複数のスライスが存在する場合はエージェントを複数呼び出す [Abiko, Access 2020]。図4のような設計にすることで、スライス数に依存せずに RB 割当てを可能とした。さらに、エージェントはスライスの要件を必要最低限の RB 割り当てで満たすよう学習することで、RB の利用効率を高めつつスライス要件の満足度最大化を目指した。




図4. Ape-X を用いた RB 割当て

評価には、学習用端末 1 台、シミュレーション用に 6 台のデスクトップ PC を使用した。1 台の端末で 7 つのシミュレーションが実行され、1 つのシミュレーションには 9 つの Actor (= 3 スライス × 3 BS) を持つため、合計 378 Actor (= 6 端末 × 7 シミュレーション × 9 Actor) となる。様々な分析を行ったが、ここでは、スライス数と性能の関係について、提案手法のスライス数のスケーラビリティの評価結果を示す。スライスがサービスに適しているかを判断する指標として NS 要件満足度 (NSRS: Network slice requirement satisfaction), RB の使用率を測定するための指標として RB 使用率 (RBUR: RB usage ratio) を定義し分析を行った。図5(a)より、すべての手法で、スライス数が増えると NSRS が低下していることが分かる。スライス数が増えると RB が必要なときに、他のスライスも RB が必要なことが増える。そのため、必要な RB を確保できずに NSRS が低下したと考える。提案手法は比較手法と比べて、NSRS がすべてのスライス数で 0.2 以上高い。このことから、提案手法を用いることでスライス数別で評価しても、既存手法よりもスライス要件を満たすことが可能といえる。特に、スライス数が 9 まででは、NSRS が 0.8 以上であり、80% のスライスが要件を満たせている。一方、図5(b)より、None-slicing は、RB を分割しないため RBUR が最も低い。また、Hard-slicing はスライス数で等分割するため、RB が必要のないときも RB が割り当てられるため、RBUR は低下している。Demand-slicing では、パケットが到達と同時に RB を割り当てるため、RB の割り当てと同時に使用される。このため、スライス数に関わらず RBUR は約 0.8 となっている。提案手法では、スライス数が増加するほど RBUR が低下している。これは、スライス数が増えるほど RB が必要なタイミングで RB を確保が難しくなる。そのため、RB の割り当てができるときに、確実にスライスの要件を満たせるように、RB を過剰に割り当てているためと考える。提案手法が RBUR よりも NSRS を優先し、RB を過剰に割り当てる方策を学習した理由として、報酬の設計が関係していると考えられる。報酬には、NSRS と RBUR を用いており、NSRS はすべての UE が要件を満たせなければ 0 となるのに対して、RBUR では RB の使用があれば 0 よりも大きくなる。また、NSRS と RBUR の積を報酬としており、どちらかが 0 になると報酬も 0 となる。そのため、0 になりやすい NSRS を向上することを優先的に学習し、RB の過剰な割り当てにつながったと考える。




図5. スライス数と NSRS, RBUR の関係

深層強化学習とネットワークシミュレータを組み合わせることで、最適な RB 割当てが可能であることを示した。しかし、ネットワークシミュレータは実環境を完全に模擬していないため、実環境特有のスライスの状態変化も想定される。実環境のみでモデルの訓練を行うことは、時間と費用を要するため非現実的であり、ネットワークシミュレータで学習後に実環境で転移学習し、実環境でモデルを補正するといった段階的なスパイラル学習法が今後ますます重要になると考える。

5. 主な発表論文等

〔雑誌論文〕 計5件（うち査読付論文 5件/うち国際共著 0件/うちオープンアクセス 3件）

1. 著者名 Abiko Yu, Saito Takato, Ikeda Daizo, Ohta Ken, Mizuno Tadanori, Mineno Hiroshi	4. 巻 8
2. 論文標題 Flexible Resource Block Allocation to Multiple Slices for Radio Access Network Slicing Using Deep Reinforcement Learning	5. 発行年 2020年
3. 雑誌名 IEEE Access	6. 最初と最後の頁 68183-68198
掲載論文のDOI（デジタルオブジェクト識別子） 10.1109/ACCESS.2020.2986050	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -
1. 著者名 安孫子 悠, 望月大輔, 齊藤隆仁, 片桐雅二, 池田大造, 水野忠則, 峰野博史	4. 巻 J102-B(6)
2. 論文標題 モバイルデータ負荷分散のための遅延耐性を考慮したハンドオーバー制御手法	5. 発行年 2019年
3. 雑誌名 電子情報通信学会論文誌 B	6. 最初と最後の頁 423-434
掲載論文のDOI（デジタルオブジェクト識別子） 10.14923/transcomj.2018MOP0001	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -
1. 著者名 Daisuke Mochizuki, Yu Abiko, Takato Sito, Daizo Ikeda, Hiroshi Mineno	4. 巻 19(7):1674
2. 論文標題 Delay-Tolerance-Based Mobile Data Offloading Using Deep Reinforcement Learning	5. 発行年 2019年
3. 雑誌名 Sensors	6. 最初と最後の頁 1-16
掲載論文のDOI（デジタルオブジェクト識別子） 10.3390/s19071674	査読の有無 有
オープンアクセス オープンアクセスとしている（また、その予定である）	国際共著 -
1. 著者名 町田 樹, 望月大輔, 安孫子 悠, 大岸智彦, 峰野博史	4. 巻 59(1)
2. 論文標題 空間的オフローディングを用いたモバイルデータオフローディングプロトコルの評価	5. 発行年 2018年
3. 雑誌名 情報処理学会論文誌	6. 最初と最後の頁 168-178
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

1. 著者名 Takaaki Kawai, Shigeru Kaneda, Mineo Takai, Hiroshi Mineno	4. 巻 27(3)
2. 論文標題 A Virtual WLAN Device Model for High Fidelity Wireless Network Emulation	5. 発行年 2017年
3. 雑誌名 ACM Transactions on Modeling and Computer Simulation (TOMACS)	6. 最初と最後の頁 1-24
掲載論文のDOI (デジタルオブジェクト識別子) 10.1145/3067664	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

〔学会発表〕 計19件 (うち招待講演 3件 / うち国際学会 5件)

1. 発表者名 内山 仁, 原田貴史, 田村桜子, 永井 彰, 峰野博史
2. 発表標題 LPWAへ暗号技術を適用したセキュア農業IoTシステムの提案と性能評価
3. 学会等名 情報処理学会 第29回CDS研究発表会
4. 発表年 2020年

1. 発表者名 峰野博史
2. 発表標題 協創モバイルプラットフォームへの期待
3. 学会等名 NTT DOCOMO テクニカル・ジャーナル (招待講演)
4. 発表年 2019年

1. 発表者名 Yu Abiko, Takato Saito, Daizo Ikeda, Ken Ohta, Tadanori Mizuno, Hiroshi Mineno
2. 発表標題 Radio Resource Allocatino Method for Network Slicing using Deep Reinforcement Learning
3. 学会等名 The 34th International Conference on Information Networking (ICOIN) (国際学会)
4. 発表年 2019年

1. 発表者名 峰野博史
2. 発表標題 深層強化学習を用いたモバイルデータオフローディングの研究
3. 学会等名 超知性ネットワーキングに関する分野横断型研究会 (RISING2019) (招待講演)
4. 発表年 2019年

1. 発表者名 Yu Abiko, Daisuke Mochizuki, Takato Saito, Daizo Ikeda, Tadanori Mizuno, Hiroshi Mineno
2. 発表標題 Proposal of Allocating Radio Resources to Multiple Slices in 5G using Deep Reinforcement Learning
3. 学会等名 IEEE 8th Global Conference on Consumer Electronics (GCCE) (国際学会)
4. 発表年 2019年

1. 発表者名 峰野博史
2. 発表標題 高精細無線LANエミュレーション環境HiFEE
3. 学会等名 情報処理学会 FIT2019 (招待講演)
4. 発表年 2019年

1. 発表者名 内山 仁, 峰野博史
2. 発表標題 先度を考慮した送信制御が可能なP-MQTTの開発と評価
3. 学会等名 情報処理学会マルチメディア, 分散, 協調とモバイル(DICOMO 2019)
4. 発表年 2019年

1. 発表者名 内山 仁, 笠原丞丞, 吉田敬正, 峰野博史
2. 発表標題 コンテンツ情報と通信環境を考慮したIoTアプリケーション向け優先度制御通信の実装と評価
3. 学会等名 第81回情報処理学会 全国大会
4. 発表年 2019年

1. 発表者名 望月大輔, 安孫子 悠, 齊藤隆仁, 片桐雅二, 池田大造, 峰野博史
2. 発表標題 深層強化学習を用いたモバイルデータオフローディング手法の紹介
3. 学会等名 Scenargie Workshop2018
4. 発表年 2018年

1. 発表者名 安孫子 悠, 望月大輔, 齊藤隆仁, 片桐雅二, 池田大造, 水野忠則, 峰野博史
2. 発表標題 遅延耐性を考慮したハンドオーバー制御に基づくモバイルデータオフローディング手法の評価
3. 学会等名 Scenargie Workshop2018
4. 発表年 2018年

1. 発表者名 Daisuke Mochizuki, Yu Abiko, Hiroshi Mineno, Takato Saito, Daizo Ikeda, Masaji Katagiri
2. 発表標題 Deep Reinforcement Learning-Based Method of Mobile Data Offloading
3. 学会等名 11th International Conference on Mobile Computing and Ubiquitous Networking (ICMU) (国際学会)
4. 発表年 2018年

1. 発表者名 Tetsuo Furuichi, Hiroshi Mineno
2. 発表標題 Proposal of IoT system with SmartContract on BlockChain
3. 学会等名 IWIN (International Workshop on Informatics) 2018 (国際学会)
4. 発表年 2018年

1. 発表者名 Takuma Tachibana, Eisuke Kasahara, Takamasa Yoshida, Hiroshi Mineno
2. 発表標題 Evaluation of Priority Control Mechanism for Remote Monitoring IoT System in Greenhouses
3. 学会等名 9th EAI International Conference on Mobile Computing, Applications and Services (MobiCASE) (国際学会)
4. 発表年 2018年

1. 発表者名 安孫子 悠, 望月大輔, 齊藤隆仁, 片桐雅二, 池田大造, 水野忠則, 峰野博史
2. 発表標題 ユーザの移動制御を利用したモバイルデータオフローディング手法の提案
3. 学会等名 第80回情報処理学会全国大会
4. 発表年 2018年

1. 発表者名 望月大輔, 安孫子 悠, 齊藤隆仁, 片桐雅二, 池田大造, 峰野博史
2. 発表標題 深層強化学習を用いたモバイルデータオフローディング手法の評価
3. 学会等名 電子情報通信学会, モバイルネットワークとアプリケーション研究会 (MoNA)
4. 発表年 2018年

1. 発表者名 安孫子 悠, 望月 大輔, 齊藤隆仁, 片桐雅二, 池田大造, 峰野博史
2. 発表標題 遅延耐性を考慮したハンドオーバー制御に基づくモバイルデータオフローディング手法の検討
3. 学会等名 電子情報通信学会, モバイルネットワークとアプリケーション研究会 (MoNA)
4. 発表年 2018年

1. 発表者名 望月大輔, 安孫子 悠, 齊藤隆仁, 片桐雅二, 池田大造, 峰野博史
2. 発表標題 深層強化学習を用いたモバイルデータオフローディング手法の検討
3. 学会等名 ITSフォーラム
4. 発表年 2017年

1. 発表者名 望月大輔, 安孫子 悠, 峰野博史
2. 発表標題 分散深層強化学習を用いたモバイルデータオフローディング手法の提案
3. 学会等名 情報処理学会マルチメディア, 分散, 協調とモバイル(DICOMO 2017)シンポジウム
4. 発表年 2017年

1. 発表者名 安孫子 悠, 望月 大輔, 峰野博史
2. 発表標題 将来移動経路の負荷を考慮したモバイルデータオフローディング手法の評価
3. 学会等名 情報処理学会マルチメディア, 分散, 協調とモバイル(DICOMO 2017)シンポジウム
4. 発表年 2017年

〔図書〕 計0件

〔出願〕 計3件

産業財産権の名称 制御量算出装置及び制御量算出方式	発明者 峰野博史, 安孫子悠	権利者 同左
産業財産権の種類、番号 特許、特願2020-058499	出願年 2019年	国内・外国の別 国内

産業財産権の名称 機械学習システム及び機械学習方法	発明者 峰野博史, 若森和昌, 望月大輔	権利者 同左
産業財産権の種類、番号 特許、PCT/JP2019/4061	出願年 2019年	国内・外国の別 外国

産業財産権の名称 機械学習システム及び機械学習方法	発明者 峰野博史, 若森和昌, 望月大輔	権利者 同左
産業財産権の種類、番号 特許、特願2018-022132	出願年 2018年	国内・外国の別 国内

〔取得〕 計0件

〔その他〕

モバイルトラフィックオフローディンググループ概要 http://www.minelab.jp/?p=4682

6. 研究組織

	氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
研究分担者	水野 忠則 (Mizuno Tadanori) (80252162)	愛知工業大学・情報科学部・教授 (33903)	

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8. 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------