

リアルタイムジオメトリ情報に基づくミリ波通信品質予測

研究代表者

西尾 理志

京都大学 大学院情報学研究科 助教

1 研究概要

ミリ波通信は次世代無線通信の高速化・大容量化の重要技術として近年注目を集めている。しかし、ミリ波通信は、端末移動に伴う建物や街路樹などによる通信路遮蔽に加えて、端末静止時においても歩行者や車両等による遮蔽が著しく通信品質を低下させる。そのため、通信環境の僅かな時間的変化で通信品質が大きく変化するという問題がある。

ミリ波通信の主要用途は大容量コンテンツ配信や大容量データ共有であり、コンテンツやデータの要求から数秒間で転送完了することが期待されるが、遮蔽による急峻な通信品質低下は大量のパケットロスや再送による大きな遅延などサービスの品質を大きく低下させる。一方、その数秒間の通信品質が予測できれば、通信品質劣化前に基地局ハンドオーバーなどの通信制御を通じて通信品質を維持したり、良質な無線リンクを優先的に用いて周波数利用効率を向上させたり、コンテンツやデータを適応に圧縮し体感品質を向上させたりなど、ミリ波通信品質の不安定性に起因する問題を根本的に解決する新たな無線通信制御が実現できる。

本研究「リアルタイムジオメトリ情報に基づくミリ波通信品質予測」では、空間イメージング技術、特に被写体との距離が取得可能な深度カメラをもとに、時間変化するミリ波通信品質を定量的に予測する技術を確立する。これまでの通信品質予測は電波の受信強度などをもとにしており、端末の移動に伴う連続的な変化は予測できても、遮蔽による突発的な変化は予測できない。一方で、これらの画像は端末や遮蔽物、周囲の反射体など、通信品質予測に必要なジオメトリ情報を断片的ながら含んでおり、遮蔽による突発的な変化も予測できる可能性がある。特に、数秒程度であれば歩行者や車両が等速直線運動すると期待でき、ジオメトリ変化とそれに伴う通信品質変化の正確な予測が期待できる。

本研究では、まずミリ波無線 LAN を対象に人体遮蔽が発生する環境下でのスループット予測手法を提案した。提案方式では、機械学習を用いて画像と通信品質の対応関係を学習し、さらに画像には時系列的に連続した画像を用いることで数百ミリ秒先の通信品質の予測を可能とする。IEEE 802.11ad 60GHz 無線 LAN 機器を用いた実験により、提案手法が 1Gbit/s の通信において 100 Mbit/s 程度の誤差でスループットを予測できることを示した。また、人体遮蔽に加えて、ミリ波車々間通信における車両間の受信電力予測手法を提案した。提案方式では、車両配置画像に対する受信電力を直接学習する方式に加えて、理論モデルからの誤差を学習する手法を提案し、受信電力が 10 dB 以下の誤差で予測できることを示した。さらに本研究ではこれら予測技術に並行し、主に車々間通信を対象に予測を応用した通信制御、特にカバレッジ拡大のための車両移動制御を検討した。車両の現在の配置と移動先での通信品質の予測情報に基づき、車両自体が自律的に移動することで、遮蔽を解消し、マルチホップ通信時の通信距離を伸長する。提案方式では強化学習を応用することで、車両移動の戦略を自律的に獲得するため中央制御局が不要である。提案方式により車両移動戦略を学習し、カバレッジが向上することをシミュレーション評価により確認した。

2 深度画像を用いたミリ波通信品質予測

2-1 はじめに

ミリ波通信は次世代無線通信における高速かつ大容量な通信のための技術として期待されている。日本では 57 GHz から 66 GHz までの 9 GHz の帯域で、それぞれ 2.16 GHz の帯域幅を持つ 4 つのチャンネルが使用可能であり、ミリ波無線通信規格である IEEE 802.11ad では 1 Gbit/s 以上の超高速通信が可能である。しかし、ミリ波通信は反射や回折損が大きく、見通し通信路が人体や車両などの障害物により遮蔽されると受信信号電力が大きく低下する。

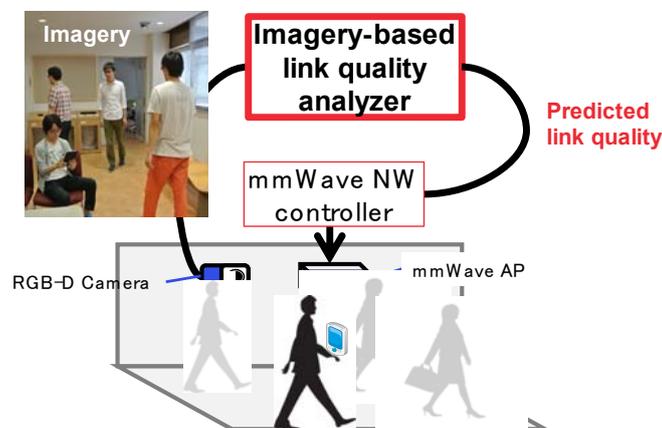
見通し通信路遮蔽問題の解決策として、通信路遮蔽発生時に端末の接続するミリ波基地局を通信品質の良い他の基地局に変更するハンドオーバーが提案されている。ここで、通信品質とはスループットや受信電力やフレーム損失率などの指標を指す。見通し通信路遮蔽による通信品質の低下は非常に急峻であるため、通信品質を常に高く保つためには遮蔽が起こった時、ハンドオーバーの制御を素早く行う必要がある。[Oguma15]で

は、ミリ波通信におけるカメラを用いたプロアクティブハンドオーバを提案している。この手法では、カメラを用いて遮蔽物の位置などの通信環境を観測し、現在や未来の津新環境を予測し、予測に基づいて遮蔽が発生する前にハンドオーバを実行する。実験では、この手法を用いることで人体遮蔽によりスループットが低下する期間を大幅に削減できることを示した。しかし、この実験では、端末とハンドオーバ候補となる基地局との間の通信品質の取得方法が課題であった。

通信品質を高く保つためにはハンドオーバ制御部はどの基地局にハンドオーバを行うかを決定する必要がある。しかし、ハンドオーバを行うたびに、直接フレームを端末と基地局間で送信するなどして通信品質を測定すると、帯域が圧迫される上、ハンドオーバの実行が遅くなってしまう。したがって、ハンドオーバ制御部は過去の通信品質などから、制御信号等を送ることなく現在の通信品質を得る必要がある。

本章では、機械学習を用いた深度画像からのスループット予測手法について述べる。この方法を用いることで、オーバーヘッドとなる制御信号を送信することなく、端末と基地局間のスループットを予測することが出来る。これにより、プロアクティブハンドオーバを行う上で、どの基地局にハンドオーバをすると高いスループットが得られるかが明確となる。本方式を RGB-D カメラと IEEE 802.11ad 準拠ミリ波無線 LAN 機器を用いたテストベッドに実装し、実験ではスループットをリアルタイムで推定した。

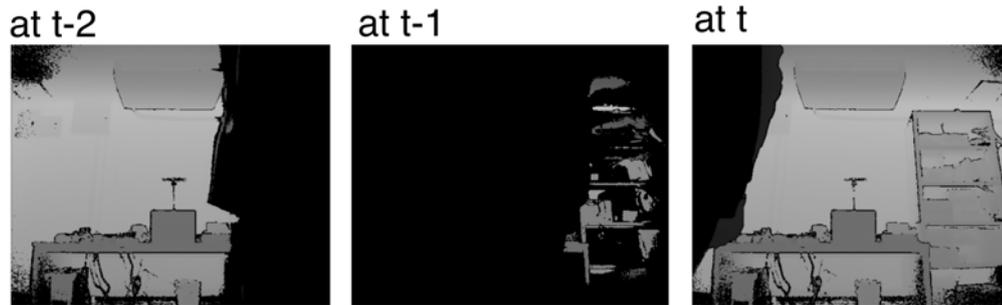
2-2 システムモデル



提案システムを上図に示す。提案システムは、ミリ波基地局、RGB-D カメラ、通信制御部、及び予測器からなる。予測器は有線ネットワークでミリ波基地局、RGB-D カメラ、及び通信制御部と接続される。RGB-D カメラはカラー画像だけでなく、距離も取得することが可能である。深度画像からはカメラの視野角内にある物体までの距離が取得できるため、ミリ波通信品質に大きな影響を及ぼす遮蔽物の位置情報の高精度な取得が可能である。RGB-D カメラの画像は接続された予測器へと送信される。予測器は機械学習アルゴリズムを用いて、画像から通信品質への写像を学習し、画像の系列から将来の通信品質を予測する。

2-3 提案方式

本方式は学習フェーズと推定フェーズからなる。基地局と端末がフレームを互いに送受信している時、基地局に接続された学習器は学習フェーズとなる。一方、基地局と端末が互いにフレームを送信していない時、基地局に接続された学習器は推定フェーズとなる。学習フェーズにおいて、学習器は RGB-D カメラから得られた深度画像とミリ波基地局から得られた実測スループットの関係性を学習する。推定フェーズにおいて、学習器は RGB-D カメラから得られた深度画像から、スループットを予測する。

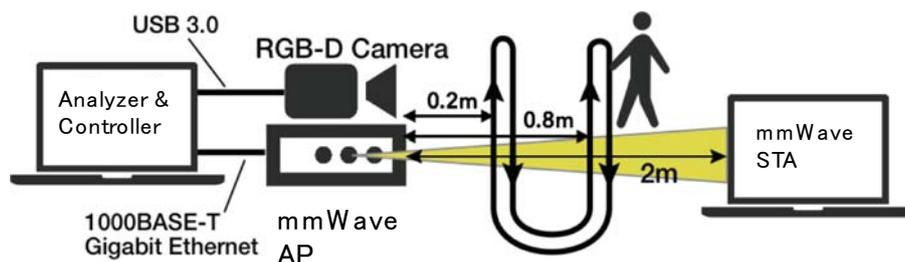


提案方式では通信品質としてスループットを時系列画像シーケンスから予測する。上図に時系列画像の一例を示す。時系列画像シーケンスはそこに映る物体のモビリティ情報を内包しており、そのモビリティがジオメトリを変化させスループットを変化させる。そこで、時系列画像の内包するジオメトリおよびそのモビリティとスループットを対応付けるモデルを構築することで、将来のスループットが予測できる。

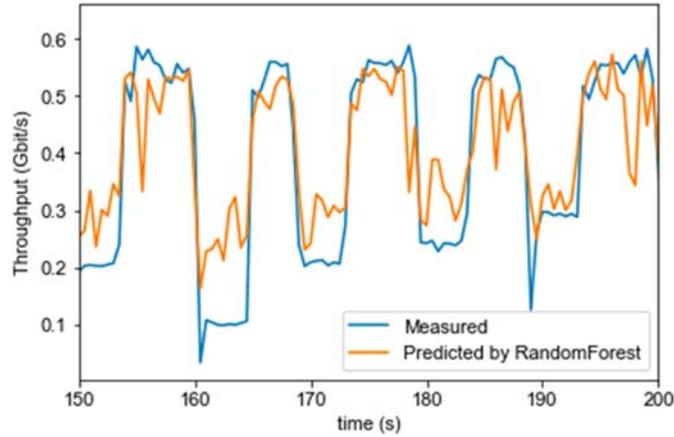
モデル構築には機械学習を用いる。予測後に制御を行うことを考慮すると予測結果の出力は高速に行う必要がある。また、随時得られる画像とスループットの実測データからモデルを更新することを考慮すると、学習の時間は短いことが望ましい。そこで本研究では機械学習アルゴリズムにランダムフォレスト [Liaw02] を用いた。ランダムフォレストはアンサンブル学習に基づく学習アルゴリズムで、高速に実行可能かつハイパーパラメータに対してロバストであり、非線形なモデルも学習可能であることが知られている。ランダムフォレストでは、複数の決定木を構築し、各決定木の出力から平均をとったものをランダムフォレストの出力とする。決定木（学習）とは二分木構造を用いた予測モデルを学習するアルゴリズムであり、特徴量に対して予測値を出力するためのルールを獲得する。ランダムフォレストでは、訓練データセットから復元抽出したデータを用いて各決定木を訓練する。このとき、各決定木ごとに、一部の特徴量のみを用いて訓練する。こうすることで、学習される決定木は多種多様となり、その集計をとることで全データを用いて単一の決定木を学習した場合より高い予測性能を獲得する。また、ランダムフォレストにおける各決定木の学習は独立に行うことができるため、並列化が容易であり、学習および予測処理の高速化が可能である。

提案手法では時系列に並んだ複数枚の画像と画像が得られた時刻から一定時間後のスループットを1つのサンプルとして訓練データを構成し、そこから復元抽出したデータで決定木を訓練し、時系列画像とスループットのマッピングを獲得する。時系列画像は時刻 t の画像に $k \Delta t$ 秒前の画像を N 枚水平方向に合成し、生成する。 k は時刻 t から数えて k 番目の画像を示すインデックスである。画像取得時刻 t から $m \Delta t$ 秒後のスループットを時刻 t を先頭とする時系列画像のラベルとして訓練データを構築した。

2-4 実験評価



本方式を実験データを用いて評価した。上図に実験システムを示す。通信機器は IEEE 802.11ad 対応機器を用い、周波数帯域は 60.48 GHz、カメラには Microsoft Kinect を用いた。トラフィックは Iperf を用いて発生させ、スループットと画像は 0.5 秒おきに測定した。訓練データとテストデータとしてそれぞれ 2993 個のデータを取得し、予測データと実測データを比較した。



上図に実測スループットと予測スループットを示す。 Δt は 0.2 秒、 $N=3$ とし、 $m\Delta t$ は 0.4 秒とした。時系列画像と機械学習を用いることで遮蔽によるスループット低下が予測できていることがわかる。特に遮蔽によりスループットが低下するタイミングが一致していることがわかる。

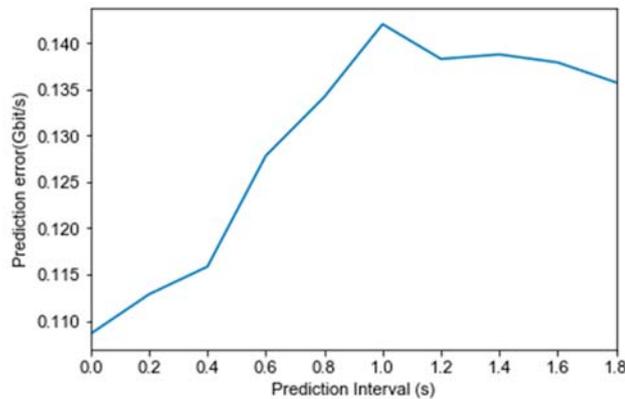


図 3 に $m\Delta t$ に対する予測誤差を示す。 $m\Delta t = 0$ のときは、画像取得時刻 t のときのスループットを予測している。予測時刻を遅くするに従って誤差が増大し、140 Mbit/s 程度で飽和した。これは今回の実験系では遮蔽時のスループットと見通し時のスループットの差が 300 Mbit/s 程度であり、また遮蔽と見通し通信時がほぼ一定間隔で訪れることから、遮蔽時と見通し時のスループットの平均値付近の値を出力するだけでも誤差が 150 Mbit/s ことに起因する。

3 画像に基づく車々間ミリ波通信品質予測

3-1 はじめに

ミリ波通信の応用先として車々間通信が注目を集めている [Choi16]。交通事故減少や高効率な交通整理を実現するため自動運転が盛んに研究開発されており、その中で車両が搭載する多数のセンサから得られるデータの共有、リアルタイムでの地図情報の更新および利用、搭乗者へのインフォテインメントの提供が検討されている。自動運転で利用されるセンシングデータは毎秒 1GB に達するという試算もあり、現在、マイクロ波帯を用いた通信規格である DSRC (Dedicated Short Range Communications) がでは最大伝送速度は 27 Mbit/s であり、帯域が不足している。ミリ波通信を応用することで十分な帯域を確保し、高精細な空間センシング情報とそれを周囲の車両と高速に共有することが可能となる。

しかし、遮蔽による信号減衰により通信リンクは断続的となる。特に、車々間通信ではトラックなどの大型車両も存在し、前章で検討した人体遮蔽に比べ、より大きな減衰や長期間な遮蔽が発生する可能性もある一方、車両自体が反射物となって新たな通信経路を生み出す可能性があり、通信環境のジオメトリが強く影響を与える。そこで本研究では、画像に基づく通信品質予測を車々間通信に応用し、自動運転車が生成した空間画像から任意車両間の通信時の受信電力を予測する手法を提案する。提案手法の性能をシミュレーショ

ン評価により明らかにする。

3-2 受信電力予測

提案予測手法では2章の方式と同様、画像、特に俯瞰画像から受信電力を予測する。俯瞰画像は道路に設置されるカメラや衛生から取得が可能であるとする。

[Yamamoto08]ではミリ波車々間通信の受信電力の予測モデルが提案されている。予測式を以下に示す。

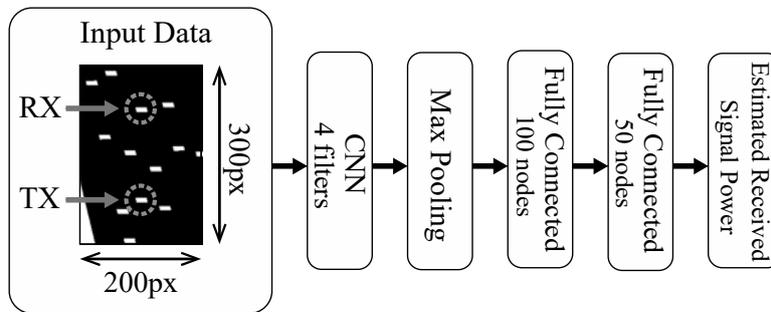
$$P_R = -17.7 \log_{10} D - 0.015D + \text{const.}$$

D は距離であり、const は定数項を表す。遮蔽の有無によって定数項が変化する。上記モデルは平均的な伝搬特性を表すものであり、ある実現値を考えると誤差が生じる。本研究では、それぞれの環境に応じた誤差項 P_E を加えた、

$$P_R = -17.7 \log_{10} D - 0.015D + \text{const.} + P_E$$

を実測データをもとに同定することを目指す。具体的には、 P_R を直接学習する方法と、 P_R は[Yamamoto08]のモデルを用いて計算し、そのモデルとの誤差 P_E を学習する方法の2つを検討した。

機械学習として、2章同様のランダムフォレストの他、Convolutional Neural Network (CNN)を用いる。CNNとは生物の視覚野の生理現象をモデル化したもので、画像の認識や分類で成果をあげている。

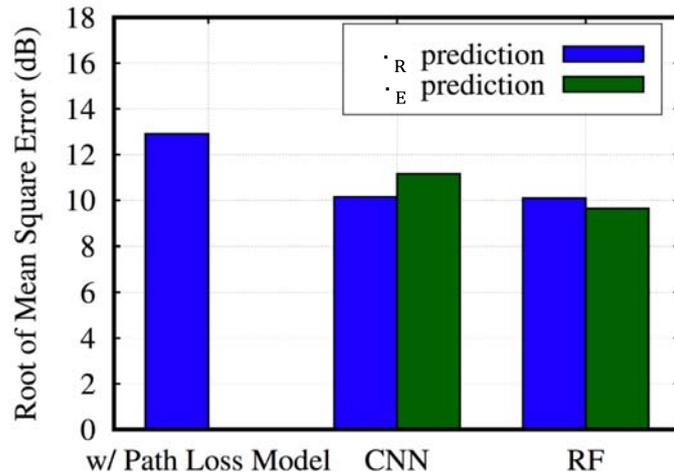


上図に本研究で用いた機械学習への入力画像の例と CNN のモデルを示す。本研究で用いた CNN は正規化層、畳み込み層、プーリング層、全結合層から構成され、受信電力の推定値を出力する。入力データは周囲の情報を表すグレースケールの画像であり、黒い箇所が遮蔽物のない場所、白い箇所が車両や建物などの遮蔽物が存在する場所を示している。入力画像では送受信車両の位置が特定の位置にくるように拡大縮小とトリミングを行う。訓練時はこの入力画像と送受信車両間の受信電力の実測値を与えて画像に対する受信電力値あるいは理論モデルとの誤差を学習する。予測時は画像から受信/誤差電力値を予測する。誤差を用いた予測では、理論モデルの予測値に機械学習から出力された誤差の和を予測値として出力する。

3-3 シミュレーション評価

提案手法の性能を計算機シミュレーションにより評価した。受信電力の真値はレイトレーシングを用いた電波伝搬シミュレータである RapLab を用いて測定し、画像はレイトレーシングに用いた三次元モデルからモノクロ画像を生成した。レイトレーシングでは、搬送波周波数 60 GHz、送信電力 10 dBm、アンテナ高 1m、指向性アンテナのビーム幅 30 度とした。車両は平均車距離 50m、最低車間距離 20m となるように車線上にランダムに配置した。電波伝搬シミュレーションにより受信電力値、その時用いた三次元モデルから俯瞰画像を生成し、ランダムフォレストあるいは CNN を訓練した。

下図に予測値の平均誤差を示す。青いバーは P_R 、緑は P_E を予測した場合の結果である。提案方式は理論モデルに基づく予測誤差より小さい誤差で予測を実現した。また、本評価においては CNN とランダムフォレストは同等の結果を示した。ランダムフォレストを用いて P_E を予測した場合がもっとも予測誤差が小さく、理論モデルを用いた場合から 3.3 dB 誤差を削減できた。



4 ミリ波通信品質予測を用いた車々間通信制御

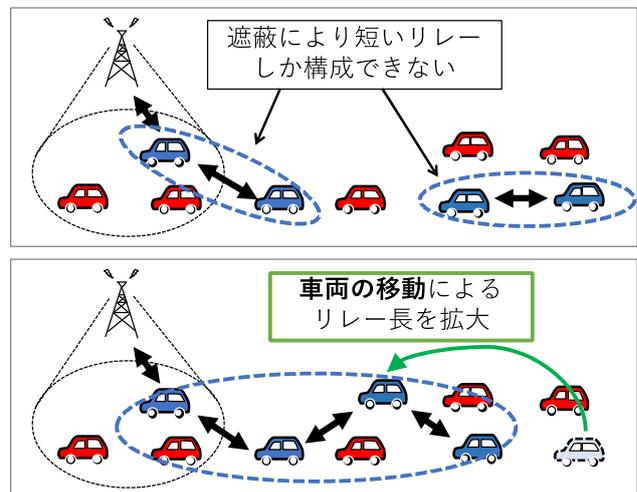
4-1 はじめに

ミリ波通信は高速な通信が可能な一方で、マイクロ波帯の電波に比べて距離および遮蔽による減衰が大きいこと、通信可能距離が短いことが課題である。コストの観点から設置できる路上基地局 (RSU: Road Side Unit) には上限があり、RSU との V2I (Vehicle-to-Infrastructure) 通信だけでは十分なカバレッジを確保できないことが予想される。従来の V2I においても、カバレッジを拡大するためにマルチホップ通信を利用することが提案されているが、マイクロ波帯を想定したマルチホップ通信は遮蔽の影響が考慮されていない。一方、ミリ波通信の遮蔽は 3 章までの研究で予測可能であることが明らかになっている。そこで

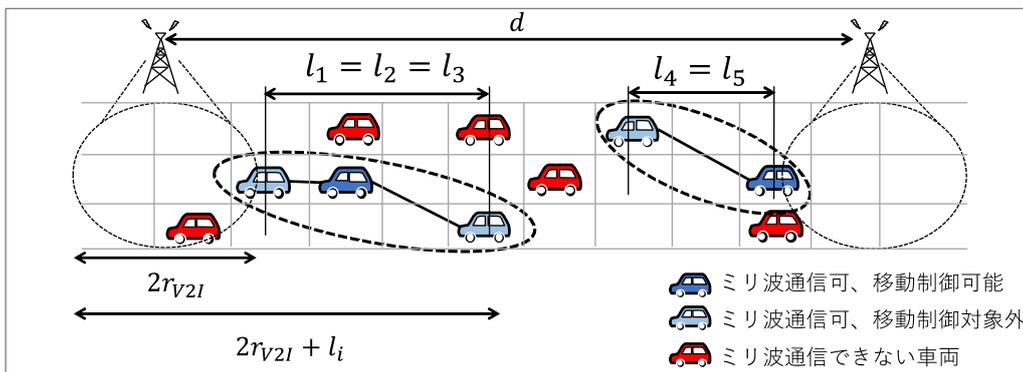
本研究では、遮蔽の影響予測もとに、マルチホップによる V2I のカバレッジを最大化する車両移動制御を提案する。自動運転車を対象として、車両自らが他の車両との相対的な位置を変更することで、遮蔽を回避し、V2V (Vehicle-to-Vehicle) 通信が見通しで行えるようにし、マルチホップ通信の距離を向上する。

マルチホップ通信やセンシングのカバレッジ向上のための移動制御については無線センサネットワーク (WSN: Wireless Sensor Network) の分野で盛んに議論されており、VFA (Virtual Force Algorithm) を用いた移動制御手法が提案されている [Chen07]。既存研究ではマイクロ波通信を想定しており、通信距離に対して通信品質が単調減少することを仮定して、各ノードが周囲のノードとの距離から移動方向を決定し、全体が等間隔に配置される移動制御を実現している。

しかし、ミリ波通信においては遮蔽による減衰があるため、通信距離に対して通信品質が単調減少するとは限らず、通信品質の良い位置に移動するために、一時的に通信品質の悪い位置を通過する必要があることが予想される。例えば、ある通信車両の移動経路上に、車両による遮蔽により通信が一時的に非見通し通信になる区間があった場合は、そのような経路が選択されず、結果として移動停止してしまい、カバレッジを拡大することができない。本稿では、モデル化が困難な環境においても長期的な利得を最大化する行動を学習可能な強化学習を用いて、遮蔽物を回避してマルチホップによるカバレッジ拡大を可能とする車両の移動制御を提案する。車両が利用する周囲の情報の次元が大きくなり、古典的な強化学習は収束に時間がかかり適用が困難であるため、関数近似として深層強化学習を利用する。また、強化学習の状態定義として、リレー長の情報を含めることで、カバレッジ拡大性能が向上することを示す。



4-2 システムモデル



上図にシステムモデルを示す。車線数 N_l の高速道路を考え、ミリ波通信のRSUが道路に沿って間隔 d で設置されているものとする。簡単のため、道路をグリッドに分割し車両はその中心に配置されるものとする。また、車両の平均時速は等しく、相対位置関係は変化しないものとする。自動車制御技術として、自動車間距離を一定に保ち走行するアダプティブクルーズコントロールがあり、この仮定はアダプティブクルーズコントロールが十分普及していることを想定している。それぞれの車両はGPS(Global Positioning System)によって得られた自身の位置情報をマイクロ波帯のDSRCにより共有しているとする。

本稿では、ミリ波対応車両の普及段階を対象とする。そのため、車両の種類としてミリ波非対応車両とミリ波対応車両を考え、ミリ波対応車両の一部の車両のみが、提案する強化学習を用いた移動制御を行うものとする。ミリ波非対応車両もDSRCは利用可能であるとし、前述の通り位置情報が取得可能である。ミリ波車両はミリ波通信できる車両同士でマルチホップリレーを構成し、RSUまでリレーを介した通信可能な範囲を拡大する。ミリ波車両とRSUの最大通信可能距離を r_{V2I} 、ミリ波車両同士の最大通信可能距離を r_{V2V} とする。また、ミリ波通信は見通し通信でのみ可能とする。移動制御可能な車両のみが強化学習によりカバレッジ拡大のために相対位置を変化させ、その他の車両は前述の通り、相対位置を変化させないものとする。車両の比率として、車両全体に対するミリ波車両の割合を R_{mm} 、ミリ波車両に対する制御対象可能車両の割合を R_c とする。

本稿では、移動制御の性能指標として車両 i がミリ波マルチホップ通信を介してRSUと通信可能な範囲を車両 i のカバレッジとして以下のように定義する。まず、車両 i のマルチホップを介したRSUまで通信可能な距離は $r_i = 2r_{V2I} + l_i$ と表される。ここで、 l_i は車両 i が属するマルチホップリレーの道路と平行方向の長さである。RSUは道路に沿って間隔 d で設置されているため、車両 i がRSUと通信できる範囲の割合は

$$C_i = \min\left\{\frac{2r_{V2I} + l_i}{d}, 1\right\}$$

と表され、これを車両 i のカバレッジと定義する。カバレッジは l_i に対して単調に増加するため、制御の目的は長いリレーを形成することとなる。

4-3 強化学習を用いたカバレッジ拡大手法

提案手法は移動制御対象の各車両がカバレッジ拡大を目的に他車両に対する自身の相対位置を変更する戦略を学習する。その際、移動方向は観測した周囲の車両の状況、具体的には車両の配置、各地点に移動したときのリレー長から判断し、決定する。この学習問題をマルコフ決定過程としてモデル化する。マルコフ決定過程における最適な戦略はQ学習によって学習可能なことが知られている [Sutton98]。提案手法では、制御対象車両を学習の主体であるエージェントとし、各車両はどの位置が最適な位置であるかについて事前知識なしにカバレッジ拡大のための移動戦略を学習する。さらに、強化学習は各時刻における短期的な利得ではなく、長期的な利得を最大化するため、局所的に通信品質がよい場所にとどまらずにカバレッジを拡大する場所に移動することが期待される。

本稿が対象とする問題設定においては観測した状態の次元が大きく古典的な強化学習手法では計算時間の観点から学習が困難になる。そこで、本研究では、強化学習における関数近似の手法として深層学習を用いる深層強化学習を応用する。特に最新の深層強化学習アルゴリズムの一つであるA3C(Asynchronous

Advantage Actor-Critic) [Mnih16]を応用する。本稿の対象とする環境は複数のエージェントが存在しているが、A3C では複数のエージェントが並列学習することで学習速度の向上に成功しており、適用が容易である。A3C の学習フェーズでは、各エージェントは一定期間独立にそれぞれの方策に従って行動し、その後、方策を更新するための勾配を計算し、他のエージェントと共有する。これにより、各エージェントの独立した学習結果を統合してモデルに反映することができ、効率的に学習を進めることができる。学習が十分進むと最適な方策に収束することが期待される。A3C では方策関数と状態価値関数を DNN(Deep Neural Network)により表現する。前述の勾配計算は、行動により得られた報酬をもとにこの DNN のパラメータに対して計算する。

行動、報酬はそれぞれ以下のように定義される。

$$A := \{forward, back, right, left, stay\}$$

$$r_{i,t} := \begin{cases} \alpha l_i & \text{if an agent selects movable direction,} \\ \alpha l_i + r_p & \text{otherwise.} \end{cases}$$

行動は車両の移動方向、あるいは停止の5つからなる。一方、報酬は、車両移動の結果として変化したりレー長 l_i をもとに計算される。 r_p はペナルティ項であり、移動できない方向、つまり、他の車両がいる場所や車線外への移動を試みたときに付加される負の値である。

次に強化学習の状態設計について述べる。状態は深層強化学習で成果を挙げている AlphaGo [Silver16]を参考に設計した。まず車両の周囲の空間をグリッドに分割する。そのグリッド空間上の各格子点に対し、車両の位置やレー長に応じて状態を定義した。まず1つ目の状態として、ミリ波対応車両の場所を用いて以下のように定義した。

$$s_{i,t}^{(1,x,y)} := \begin{cases} 1 & \text{if a mmWave vehicle positions at } (x,y), \\ 0 & \text{otherwise,} \end{cases}$$

ミリ波対応車両があるグリッドに存在すれば1、いなければ0となる。これにより、ミリ波対応車両の配置を表す二次元のバイナリ画像のようなものが生成される。2つ目の状態は、ミリ波非対応車両、すなわち、遮蔽物になる車両の位置を用いて以下のように定義した。

$$s_{i,t}^{(2,x,y)} := \begin{cases} 1 & \text{if a non-mmWave vehicle positions at } (x,y), \\ 0 & \text{otherwise,} \end{cases}$$

これは状態1と同様に、ミリ波非対応車両の配置を表す二次元のバイナリ画像で表現される。3つ目の状態として、移動可能かどうか、すなわち、その場所に車両がないかどうかを表す特徴を以下のように設計した。

$$s_{i,t}^{(3,x,y)} := \begin{cases} 1 & \text{if } (x,y) \text{ is empty,} \\ 0 & \text{otherwise.} \end{cases}$$

これも状態1、2と同様に、車両の可能な移動先を表す二次元バイナリ画像となる。最後に車両があるグリッドに移動した場合のレー長、すなわち報酬の予測値を用いて以下のように状態を定義した。

$$s_{i,t}^{(4,x,y)} := \rho \hat{l}_i(x,y),$$

ここで、 ρ は正規化パラメータである。レー長は移動先で通信を行って確定するものであり、移動前は通常はわからない。そこで、2,3章の技術を用いて移動後の受信電力を予測し、事前に獲得可能なレー長

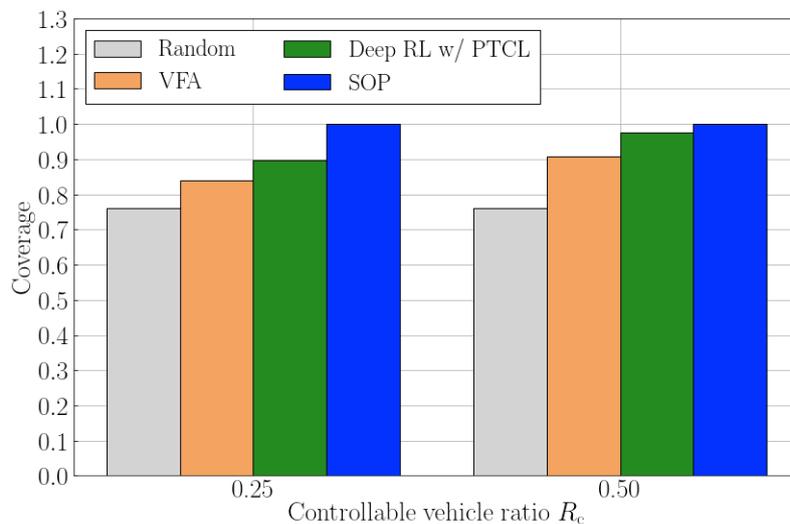
を予測することで、この状態が利用可能となる。本稿では、予測が理想的に行われるものとして、周囲の車両は移動しないものとしたときの自車両移動後のリレー長を状態として与える。

これらの行動、報酬、状態と A3C を用いて車両の移動戦略を学習する。

4-4 シミュレーション評価

2 km、2 車線の車線上に車両をランダムに配置した状態を初期状態とした。本評価では戦略を獲得する学習フェーズと評価を分けて行った。まず学習フェーズでは車両の密度を 0.02 veh/m/lane、ミリ波車両の割合 $R_{mm} = 0.4$ 、移動制御可能なミリ波車両の割合 $R_c = 0.25$ とした。学習完了後、得られた方策関数を使って車両密度 0.02 veh/m/lane、 $R_{mm} = 1$ 、 $R_c = 0.25$ 、0.5 の環境でエージェントを移動させカバレッジを評価した。その他のシミュレーション諸元を下表に示す。

シミュレーション範囲	1 km
車線数	4
車線幅	3.5 m
グリッドサイズ	3.5 m × 5 m
RSU 間隔	1 km
車々間通信可能距離	50 m
路車間通信可能距離	100 m
周囲車両の観測範囲	200 m
報酬の減衰係数	0.2
車両の移動回数	300 回
パラメータ更新間隔	5 ステップ
車両密度	0.02 veh/m/lane
ミリ波車両の割合	40%
エージェント車両の割合	25%, 50%



上図に強化学習による移動制御とランダム配置およびVFAによる移動制御[Chen07]と集中制御で車両配置最適化を行った場合[Taya18]のカバレッジを示す。強化学習を用いた提案方式は、ランダム配置やVFAによる移動制御よりも高いカバレッジを達成できることがわかる。また、移動制御可能な車両の割合が増えると、本評価における最大値であるカバレッジ1.0に近い結果が得られた。

5 まとめ

本研究では、深度画像をもとに時間変化するミリ波通信品質を定量的に予測する技術とそれらをもとにした通信制御を検討した。まずミリ波無線LANを対象に人体遮蔽が発生する環境下でのスループット予測手法を提案し、1Gbit/sの通信において100 Mbit/s程度の誤差でスループットを予測できることを示した。人体遮蔽に加えて、ミリ波車々間通信における車両間の受信電力予測手法を提案した。理論モデルからの誤差を学習することで、受信電力が10 dB以下の誤差で予測できることを示した。加えて、通信範囲拡大のための車両移動制御を検討した。車両の現在の配置と移動先での通信品質の予測情報に基づき、車両自体が自律的に移動することで、遮蔽を解消し、マルチホップ通信時のカバレッジが向上することをシミュレーション評価により確認した。

【参考文献】

- [Liaw02] A Liaw and M. Wiener, “Classification and Regression by randomForest,” *R news*, vol. 2, December, pp. 18-22, 2002.
- [Choi16] J. Choi, V. Va, N. Gonzalez-Prelcic, R. Daniels, C.R. Bhat, and R.W. Heath, “Millimeter-wave vehicular communication to support massive automotive sensing,” *IEEE Commun. Mag.*, vol. 54, no. 12, pp. 160-167, Dec. 2016.
- [Oguma15] Y. Oguma, T. Nishio, K. Yamamoto, and M. Morikura, “Implementation and evaluation of reactive base station selection for human blockage in mmWave communications,” *Proc. the 21st Asia-Pacific Conference on Communications (APCC 2015)*, pp. 199-203, Kyoto, Japan, Oct. 2015.
- [Yamamoto08] A. Yamamoto, K. Ogawa, T. Horimatsu, A. Kato and M. Fujise, “Path-loss Prediction Models for Intervehicle Communication at 60 GHz,” *IEEE Transactions on Vehicular Technology*, vol. 57, no. 1, pp. 65-78, Jan. 2008.
- [Chen07] J. Chen, S. Li, and Y. Sun, “Novel deployment schemes for mobile sensor networks,” *Sensors*, vol. 7, no. 11, pp. 2907-2919, 2007.
- [Sutton98] R.S. Sutton and A.G. Barto, *Reinforcement learning: An introduction*, vol. 1, MIT press Cambridge, 1998.
- [Mnih16] V. Mnih, A.P. Badia, M. Mirza, A. Graves, T. Lillicrap, T. Harley, D. Silver, and K. Kavukcuoglu, “Asynchronous methods for deep reinforcement learning,” *International Conference on Machine Learning*, pp. 1928-1937, 2016.
- [Silver16] D. Silver, A. Huang, C.J. Maddison, A. Guez, L. Sifre, G. Van Den Driessche, J. Schrittwieser, I. Antonoglou, V. Panneershelvam, M. Lanctot, et al., “Mastering the game of go with deep neural networks and tree search,” *Nature*, vol. 529, no. 7587, pp. 484-489, 2016.
- [Taya18] A. Taya, T. Nishio, M. Morikura, and K. Yamamoto, “Coverage expansion through dynamic relay vehicle deployment in mmWave V2I communications,” *Proc. of IEEE 87th Vehicular Technology Conference (VTC Spring)*, pp. 1-5, 2018.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
----	----------	------

Coverage Expansion through Dynamic Relay Vehicle Deployment in MmWave V2I Communications	Proceedings of the 2018 Spring IEEE 87th Vehicular Technology Conference	2018年6月
機械学習による無線通信品質予測と通信制御	電子情報通信学会 スマート無線研究会	2018年5月
深層強化学習を用いた車両移動によるミリ波路車間通信のカバレッジ拡大	電子情報通信学会総合大会	2018年3月
ミリ波路車間通信のカバレッジ拡大のための深層強化学習による車両移動制御	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	2018年2月
コネクテッドカーのためのマルチホップミリ波通信によるカバレッジ拡大	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	2017年11月
車車間ミリ波通信における空間情報を用いた受信電力推定	電子情報通信学会ソサイエティ大会	2017年9月