

# 車両 IoT 向け自己進化型分散トラスト管理

代表研究者

策力木格

電気通信大学 大学院情報理工学研究科 准教授

## 1 研究調査の目的・意義

近年、自動運転、高度交通システムの実現に向けて、自律分散車車間通信を活用した IoT (Internet of Things) システム研究の取組が進められている。数多くの大学、研究機構、企業が通信品質関連課題に取り組んでいるが、ネットワークに流れるメッセージとそれの送信者のトラスト管理に関する研究が十分行われていない。現実のシステムでは、ノード（車両）が誤った情報を提供することもあるれば、メッセージが改ざんされることもある（図 1 を参照）。どの情報が信用できるかを見極めるために車両ネットワークの特性を考慮したトラスト管理仕組みが必要となる。下記特性により、車両 IoT システムにおける信用の基盤を確保することが非常に困難な課題である：①評価尺度の複雑性②インフラなし自律分散環境③ダイナミックなネットワークトポロジ。本研究では車両 IoT システムのための自己進化型マルチエージェントトラスト管理手法並びにコンピュータシミュレーション、実証実験による評価を行う。具体的には、図 1 に示すように、ファジィ論理を用いてノードの位置情報、信用、ノード間行動の相関性、行動履歴等複数の要素を統合的に考慮し、ダイレクトトラストを計算する、または強化学習を用いてマルチホップにおけるインダイレクトトラスト（直接観測できない事件に対するトラスト）を更新する手法を用いる。提案手法ではファジィ論理を用いて上記①の問題を解決し、マルチエージェント強化学習を用いて②の問題を解決する。また転移学習を用いてネットワークに新規参加するノードに他のノードが学習した情報を転送し強化学習の収束を加速することで③の課題を解決する。

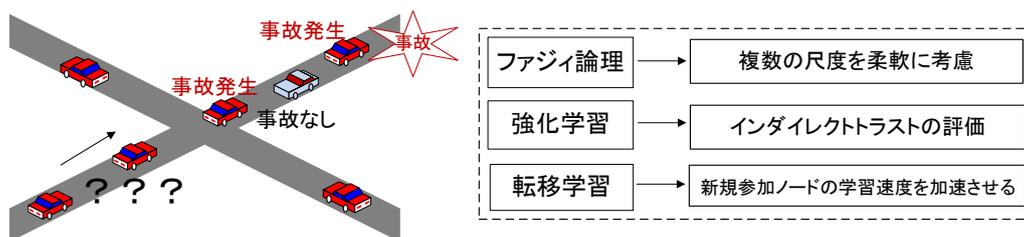


図 1 車両ネットワークにおけるトラスト管理課題と提案手法。

## 2 国内外の研究動向及び本研究を着想するに至った経緯

近年車両ネットワークを用いた高度交通システム (ITS) の更なる展開が注目を浴びている。IEEE VTC, IEEE VNC (トヨタ後援), ACM VANET などの国際会議で、大学、研究機構、企業から研究者が集まって関連課題と解決案を検討している。車両ネットワークの実用化のためには実環境での評価が重要であるため、実証実験なども行われている。日本では、平成 24 年 4 月 1 日から新交通管理システム (UTMS) 協会が設立された。通信事業者、トヨタなどの自動車関連企業が参加している。新交通管理システム協会の主催で、車両ネットワークの ITS での利用可能性について実証実験が行われている。米国では、University of Michigan-Dearborn, UCLA (University of California, Los Angeles) などが実車両ネットワークを用いて実験をしている。欧州の CTTC (Centre Tecnologic de Telecomunicacions de Catalunya) も関連研究と実証実験などに関わっている。しかし、既存の研究は端末のトラストを考慮したマルチホップ通信について十分考慮していない。無線電波伝送距離、車の移動速度などの原因により、マルチホップ通信の検討は必要である。また、自律分散ネットワークにおけるトラスト管理も重要な研究課題となる。

マルチエージェントシステムを用いて車両 IoT システムのトラスト管理課題を解決することは、革新的な研究課題である。特に、インダイレクトトラストの管理とそこにおける車両移動の影響が既存研究（上記参考文献 [1, 2] を含む）では検討されていない。本システムで提案するマルチエージェントトラスト管理手法は、車両 IoT だけではなく、分散特性を持つ IoT システム一般においても非常に有意である。またファジィ論理、強化学習、転移学習を用いたトラスト管理についての研究は、国際的にも初めての試みであると言える。フ

フェジ理論を利用することにより、通用性の高いトラスト評価手段が期待される。強化学習を用いることで自己進化型トラスト管理手法が期待される。転移学習は強化学習の収束を高速化することができるため、端末の移動性が高い車両ネットワークにおいて有効なトラスト管理が可能となる。またトラスト管理機能を実ネットワーク環境にて評価することは、実用的なシステムを設計するために必須であり、非常に重要な課題であると考えられる。

#### ■ 車両 IoT システムにおけるトラスト管理の重要性

実際に使用できる IoT システムを設計するためには、ネットワークに流れるメッセージの真実性を確認できる仕組みが重要である。今までの車両ネットワークの研究は、通信品質に関するものが多く、情報の信憑性評価、メッセージが改ざん対策などにおける研究が不十分である。誤った情報が効率よく遮断されないとネットワーク全体に対する悪影響を及ぼすため、本研究では車両ネットワークの特性を考慮したトラスト管理手法の研究を行う。研究代表者の業績を本研究で提案するトラスト管理手法と組み合わせることで Trustworthy（高信頼）車両 IoT システムの実現が可能となる。

#### ■ 実環境での評価の必要性について

従来の車両 IoT システム用プロトコルの評価にシミュレーションを用いていることが多い。しかしながら、自動運転、高度交通システムなどの通信品質要求が高いアプリケーションに対応するためには実環境での検証が重要である。そこで本研究では、提案トラスト管理手法を実際の無線デバイスに実装し、実無線ネットワーク、実アプリケーションにおいて評価し、その有効性を確認する。

### 3 研究調査の方法

#### 3-1 技術背景

近年、自動運転、高度交通システムの実現に向けて、自律分散車車間通信を活用した IoT システム研究の取組が進められている。車車間通信を利用することで、見通しの悪いところの道路状況の確認、より正確かつ迅速な交通情報案内、効率的な事故防止支援システム、道路交通情報システムの実現が可能となる。トヨタをはじめ数多くの企業、大学、研究機構が通信品質関連課題に取り組んでいるが、ネットワークに流れるメッセージとその送信者のトラスト管理に関する研究が十分行われていない。自律分散特性により、車両 IoT システムにおける信用の基盤を確保することが非常に困難である。現実のシステムでは、ノード（車両）が誤った情報を提供することもあれば、メッセージが改ざんされることもある（図 2 を参照）。どの情報が信用できるかを見極めるために車両ネットワークの特性を考慮したトラスト管理仕組みが必要となる。

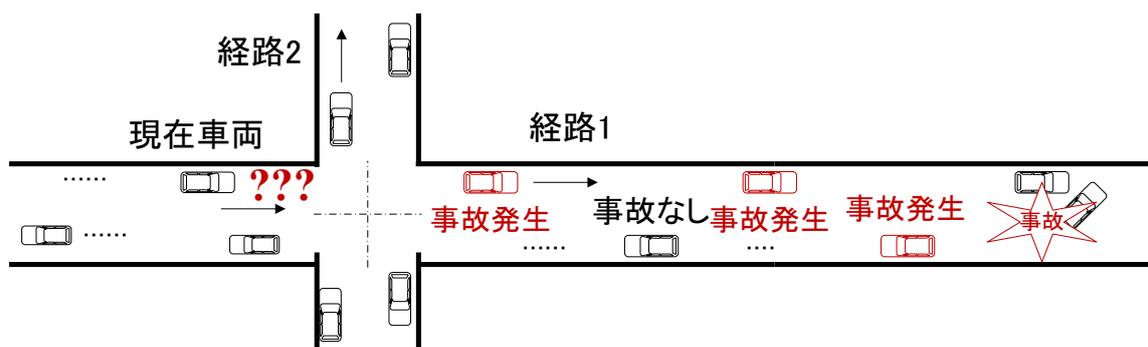


図 2 車両 IoT におけるトラスト管理（悪意端末、データ改ざんを考慮する必要がある）

車両ネットワークにおけるトラスト管理についての最近の研究としては、[1-2]があげられる。[1]では複数の車両から送信されるメッセージの内容にコンフリクトがあった場合の情報フィルタリング手法を提案している。しかし、新しいノードの参加やノードの離脱におけるトラストの更新方法が十分検討されていない。ノード参加時において、参加者に短時間内で、現システムに関する情報を伝える必要がある。またノードが離脱する前に自分が所持している情報を他のノードと共有する必要がある。[2]ではメッセージの内容とノード位置情報に基づきメッセージの真実性に対する評価を行う方式を提案している。しかし、[1, 2]ではインダイレクトトラスト (Indirect Trust) の更新方法が検討されていない (インダイレクトトラストとは、自分が直接観測できない事件に対するトラストのこと；主に他のノードの知見に基づく判断である)。車両ネットワークにおいて、通信距離の制限により、メッセージがマルチホップで送信される場合があるため、

ダイレクトトラスト(Direct Trust)とインダイレクトトラスト両方を考慮した更新方法が必要となる。

車両ネットワークは下記の特性を持っている：①評価尺度の複雑性（通常のクラウドシステムと比べて計算、記憶、通信リソースが制限される一歩、情報の真実性を評価するために周囲のノードの位置情報、信用、ノード間行動の相関性、行動履歴等複数の要素を考慮しなければならない）、②インフラなし自律分散環境(すべての情報共有を携帯電話ネットワークなどのインフラあり通信で行うのは現実的ではないため、集中制御が難しい)、③ダイナミックなネットワークトポロジ（車両の移動によりネットワーク形態が変化する）。

### 3-2 提案手法

#### (1) 概要

本研究ではファジィ論理を用いてノードの位置情報、信用、ノード間行動の相関性、行動履歴等複数の要素を統合的に考慮し、ダイレクトトラストを計算する、または強化学習を用いてマルチホップにおけるインダイレクトトラストを更新する手法を用いる。提案手法ではファジィ論理を用いて上記①の問題を解決し、マルチエージェント強化学習を用いて②の問題を解決する。また転移学習を用いてネットワークに新規参加するノードに他のノードが学習した情報を転送し強化学習の収束を加速することで③の課題を解決する。申請者の予備研究[3]では車両ネットワークにおける高効率な経路選択アルゴリズムを提案している。[4]では接続経路の匿名化を実現するためのTorネットワークの品質を向上させる提案を行っている。本研究では上記の研究経験[3,4]を活かして、車両IoTシステムのための自己進化型マルチエージェントトラスト管理手法並びにコンピュータシミュレーション、実証実験による評価を行う。提案手法を実デバイスに実装して、実際に車両ネットワークを構築して、提案手法の実環境での動作検証を行う。さらに現実のアプリケーションを用いて評価する。動作検証により、提案手法の実用化に向けた課題を明らかにして、実際に使用できる見通しをつける。

#### (2) ダイレクトトラストの評価手法

直接観測できる範囲内のノード(車両)に対しては、ファジィ論理を用いたトラスト評価手法を設計する。提案手法では、各ノードが自律分散的に周囲のノードに対するトラスト評価を行い、それを自身の隣接ノードと共有する。ノード(車両)はその位置情報、隣接車両に対するトラスト評価を含むHelloメッセージを定期的を送信する。Helloメッセージの送信間隔をデフォルトで1秒とする(場合により調整可能である)。Helloメッセージを受信したノードは、自身のすべての隣接ノードの位置情報と評判(他ノードの評価値から取得)情報を得る。これら情報に基づき、トラスト評価を行う。トラスト評価には、周囲ノードの位置情報、ノードの信用、ノード間行動の相関性(同じグループに属するか)、ノードの行動履歴などを考慮する必要がある。しかし、これら情報とトラストの関係は車両ネットワークにおける車両の分布や移動速度に依存し、最適解を求める画一的な評価式を求めるのは難しいと考えられる。ノードで保持している情報は定期的なHelloメッセージの交換から得られたものであるため、必ずしも正確ではなく、不完全、不確かであるといえる。これらの理由からノード(およびメッセージ)のトラスト評価は難しい問題となる。

そこで本研究では、図3に示すように、ファジィ論理により周囲ノードの位置情報、ノードの信用、ノード間行動の相関性、ノードの行動履歴を統合化する効率的かつ柔軟なトラスト評価方式を提案する。ファジィ論理は人間の思考と似たような近似的な推論を扱うことができ、複雑なシステムを制御することが可能となる。さらに本研究では、メンバシップ関数などファジィパラメータの設定を、環境のフィードバックに基づき自動的に行う方式を利用する。



図3 ファジィ尺度を用いた隣接ノードのトラスト評価手法。

ファジィ集合論は、複雑なシステムを「曖昧」ととらえることで最適に制御するアルゴリズムおよび理論である。ファジィ集合論は、要素がある集合にどの程度属しているかという、中間的な所属状態を許容した

集合論である。これにより、あいまいな表現（例えば{とても大きい, やや大きい, やや小さい, とても小さい}など、以下言語表現と呼ぶ）との対応関係を扱うことができる。ファジィ集合論では、ファジィ集合に関するファジィ演算を定義している。ファジィ論理は、ファジィ集合論から派生したもので、近似的な推論を扱う論理体系である。ファジィ論理は実世界の複雑な問題を扱うことが、機械制御などの様々な分野で利用されている。ファジィ論理では、ある要素を複数の言語表現と対応付け、その対応の度合い（メンバシップ）を管理する。さらに、言語表現を用いたファジィルールに基づいた推論により、様々な制御を実現する。ファジィルールは、IF/THEN規則やそれに類するもの（例えばファジィ関係行列）で規定される。

本研究では、被評価対象のノードに対して、ファジィ論理を用いてトラスト評価値を計算する。具体的な手順は以下の通りである。

- ファジィ化

ファジィ化とは、数値で表される量を、メンバシップ関数を用いて言語表現に置き換えることである。周囲ノードの位置情報、ノードの信用、ノード間行動の相関性、ノードの行動履歴を示す各要素に対して、それぞれの度合いを示す言語表現と、対応するメンバシップを得る（考慮する要素に対しては拡張または変更可能とする）。具体的な数式などは[5]に説明している。

- ファジィルールの適用

各要素の言語表現から、トラスト値を表す言語表現を導くルールを事前に定義しておく。ファジィ化の結果とこのルールとのマッチングをとることにより、ランクと対応するメンバシップを求める。上述のように各要素が各言語表現にどの程度属するかを計算した後、送信ノードが事前に定義されている IF-THEN 形式のルールを用いてノードのトラストレベルを評価する。ルールの判定結果を表すランクの言語表現としては {Perfect, Good, Acceptable, Unpreferable, Bad, VeryBad} を定義する。

三つの要素を考慮したルールの定義例として

Rule1: 要素1が Good, 要素2が Good, 要素2が Good であれば, このノードのトラストは Perfect;

Rule2: 要素1が Good, 要素2が Good, 要素2が Medium であれば, このノードのトラストは Good;

Rule3: 要素1が Good, 要素2が Good, 要素2が Bad であれば, このノードのトラストは Unpreferable;

... ..

Rule25: 要素1が Bad, 要素2が Bad, 要素2が Good であれば, このノードのトラストは Bad;

Rule26: 要素1が Bad, 要素2が Bad, 要素2が Medium であれば, このノードのトラストは VeryBad;

Rule27: 要素1が Bad, 要素2が Bad, 要素2が Bad であれば, このノードのトラストは VeryBad;

ルールが多数存在するため、解の合成を行う必要がある。ここでは Min-Max 法を用いる。例えば、Rule1 に対して、要素1 (Good) の度合いが 0.9, 要素2 (Good) の度合いが 0.8, 要素3 (Good) の度合いが 0.7 だとする。Min-Max 法では前件部の演算は AND (Min) 演算であり、3つの値の最小をとり、前件部のグレード値は 0.7 となる。したがって、Perfect の度合いは 0.7 となる。またルール毎に得られたランクの MAX 演算を行う。このようにファジィルールを複数組み合わせることによって、結論を言語表現で得る。

- 非ファジィ化

非ファジィ化とはメンバシップ関数を用いて言語表現の結論を数値で置き換えることである。ルールの適用の結果得られた中継ノードのランクを、メンバシップ関数を用いて数値に置きかえ、この被評価ノードの中トラスト値を決定する。提案手法の出力メンバシップ関数を事前に定義する。ここでは、非ファジィ化には重心法 (COG: Center of Gravity) を用いる。

### (3) インダイレクトトラストの評価手法

直接観測できない距離に存在するノードに対するインダイレクトトラスト (Indirect Trust) の確立・更新方法に関する提案と評価を行う。マルチホップネットワークにおいては、直接観測できないメッセージ、ノードに対するトラスト評価はもっと困難である。これに対して本研究では、マルチエージェント強化学習を用いてマルチホップネットワークにおけるトラストのディスカウント (割引) を行う仕組みを採用する。提案方式では、ファジィ論理を用いて隣接ノードのトラスト評価を行い、その評価値を強化学習コントローラで利用し、ネットワーク全体に対するトラストを学習する (図4を参照)。強化学習における状態観測は、Hello メッセージのやり取りで実現される。強化学習アルゴリズムとして Q-Learning を用いる。無線ネット

ワークの帯域制限を考慮し、各ノードは自分の Q-Table の一部のみを Hello メッセージに乗せる。ファジィ論理は人間の思考と似たような近似的な推論を扱うことができ、複雑なシステムを制御することが可能となる。強化学習は、現在の状態を観測し、一連の行動を通じて報酬が最も多く得られるような方策（一番信頼できるノード）を学習できる。ファジィ論理と強化学習を組み合わせることで、ネットワークにおけるすべてのノードに対して、定期的にトラスト評価を行うことが可能となる。

提案手法では、Q-Learning を用いてマルチホップにおけるトラストの値を決定する。各車両が学習エージェントになり、他の車両と Hello メッセージの交換を行いながら、隣接ノードではない車両に対するトラスト値を更新する。ネットワークノード（車両）のトラスト分布が強化学習の状態となる。ある被評価ノードに対して、学習エージェントの実施する行動がトラスト更新に参考する次の車両を選択することである（その車両の知見をいかして自分が観測できない被評価ノードに対するトラスト値を更新する）。ネットワークにおけるすべてのノードの集合はエージェントが選択可能な行動の集合となる。特定の被評価ノードに対して、そのノードの隣接ノードが直接のプラス報酬を得る。その報酬がホップ数の増加により、割引され最終的に評価ノードに届く。具体的には、1 ホップにおけるトラスト値をファジィ論理で評価し、マルチホップにおけるトラストは強化学習を用いて評価することである。強化学習とファジィ論理を組み合わせることで、マルチホップにおけるトラストをより正確に評価することができる。

また、転移学習を用いて、新規参加ノードの学習速度を加速する方法を提案する。ネットワークに新規参加したノードに対して、すでに学習した知識を他のノードから提供してもらうことで強化学習の収束を高速化することを目標とする。転移する知識は周囲ノードに対するトラスト評価の Q-Table の一部である。図 4 に示すように、車両ネットワークにおけるトラスト管理手法を開発する。

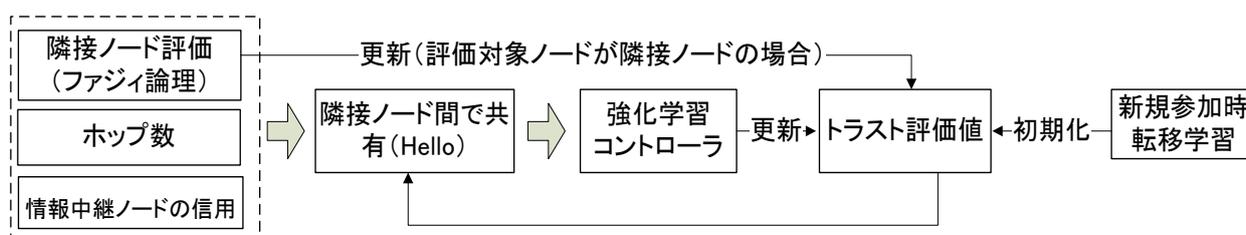


図 4 提案マルチエージェントトラスト管理手法（ファジィ論理を用いた隣接ノード評価，強化学習を用いたマルチホップトラスト評価と転移学習を用いたトラスト転移）。

#### （４）提案手法の検証

##### ■ 検証方法

実証実験，コンピュータシミュレーションの 2 種類の方法を利用して提案プロトコルの性能評価を行った。実証実験には、提案プロトコルを Ubuntu OS (Debian GNU/Linux をベースとしたオペレーティングシステム) に実装して、ノート PC (Ubuntu12.04 がインストールされている) を車に搭載させることにより、実車両アドホックネットワークにおける動作確認をした。車両間でアドホック通信を行い、その性能を評価した。ノート PC 上に提案プロトコルと比較対象の従来手法が実装されている。実験では、10 台の車両を利用した。無線通信では、2.4GHz 帯を利用した。実験結果により提案プロトコルが実環境において動作可能ということを検証した。より大規模なネットワークにおける性能評価には、ネットワークシミュレータ ns-2.34[6]を用いた。悪意ノードの検出効率を評価するためには適合率(Precision)、再現率(Recall)を用いた。異なる悪意ノード数、異なるホップにおいて従来手法と比較した。ここで従来方式とは、既存方式でよく用いられる各ノード観測に基づいた決定論方式を指す。また、悪意ノードの検出精度が実際の通信性能に対する影響を明らかにするため、ユニキャスト通信、ブロードキャスト通信において提案方式と従来方式の packets 到達率を比較した。下記シミュレーション環境と結果を示す。

##### ■ 検証結果

表 1 にて主なシミュレーションパラメータを示している。その他パラメータは[5]と同じである。まず、悪意ノード数の変化に注目し、提案手法を従来手法と比較した。この従来手法とは、各車両が自分の直接観測した情報または他の車両からの情報(間接的な観測)に基づいて悪意ノードを識別する決定論方式である。具体的には、あるノードを悪意のあるノードと判別した場合はその判別を変えない方法である。このような

手法を用いるとパケットロスが高い車両ネットワーク環境では、誤判断が行われる場合が発生する。提案手法はファジィ論理に基づき、周囲ノードの位置情報、ノードの信用、ノード間行動の相関性、ノードの行動履歴を統合化する効率的かつ柔軟なトラスト評価方式を用いているため、動的な車両ネットワーク環境においてより正しい判断を行うことが可能である。

表 1 シミュレーションパラメータ

トポロジ	長さ 2000 メートル 4 車線の直線道路
ノード数	200
最大速度	100 km/h
車両移動モデル	直線道路移動モデル[7]
MAC 層	IEEE 802.11p MAC (27 Mbps)
無線伝送モデル	Nakagami モデル
シミュレーション時間	1500 秒

図 5 は異なる悪意ノード数における適合率の比較である。適合率とは、正しく検出した悪意ノード数を悪意ノードと判別したノード数で割った数である。ここでは 1 ホップ距離の隣接ノードのみを対象としている。悪意のあるノードは確率 0.3 で “Bad Mouth Attack” を用いて攻撃を行い、さらに確率 0.3 でパケットをドロップする設定である。図 5 によると、提案手法が従来手法より高い適合率を示している。車両ネットワーク環境では、車両の移動、チャンネルフェージングなどによりパケットロスが発生するため、ノードのトラストを評価する時に無線チャネルの不安定な特性を考慮する必要がある。従来手法はこれを考慮していないため、効率が悪い。悪意ノード数（悪意のあるノードの数）の増加により二つの手法とも判別精度が低下するが、提案手法に対する影響が小さい。これは提案手法のファジィ論理を用いたトラスト評価方式が有効であることを示している。

異なる悪意ノード数における再現率の比較を図 6 に示している。ここでの再現率とは、正しく検出した悪意ノード数を全悪意ノード数で割った結果である。提案手法が従来方式よりも高い再現率を示していることから、提案手法の悪意ノードを検出できる確率が高いことが分かる。また、悪意ノード数の増加が提案手法の性能に対する影響が相対的に低いことが分かる。

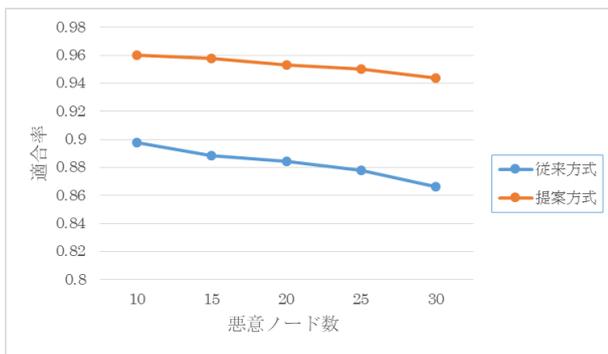


図 5 異なる悪意ノード数における適合率の比較

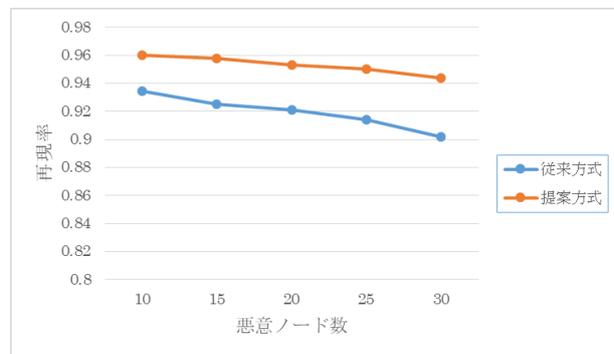


図 6 異なる悪意ノード数における再現率の比較

図 7 と図 8 はそれぞれホップ数の変化における適合率と再現率を示している。ホップ数の増加に従い、従来手法の適合率が激減することに対し、提案手法は安定した適合率を表している。これは、強化学習を用いたインダイレクトトラスト評価が有効であることを証明している。提案手法はファジィ論理を用いて複雑な環境における直接観測できる範囲内のトラスト評価を実現し、さらにマルチエージェント強化学習を用いてインダイレクトトラスト評価を行うため、ホップ数に関わらずよりよい性能を提供できる。再現率についても同じ結果が示されている。よって、提案手法の悪意ノード検出効率は既存手法より著しく高いといえる。

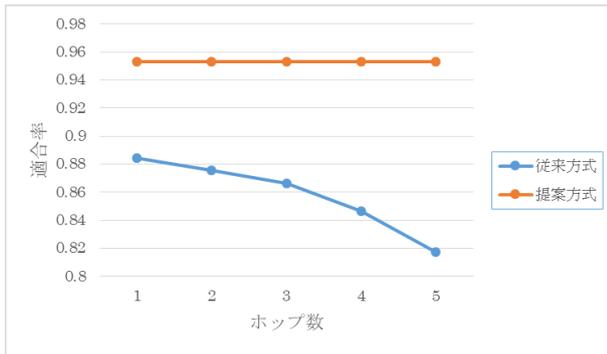


図 7 異なるホップ数における適合率の比較

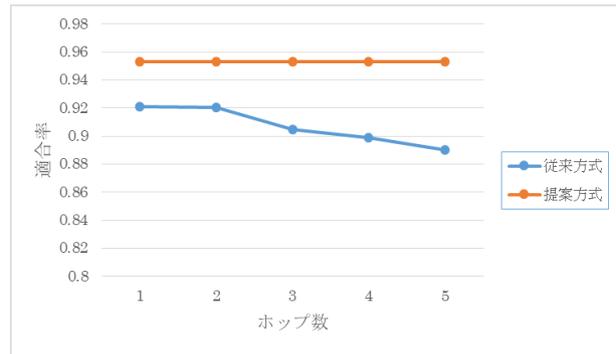


図 8 異なるホップ数における再現率の比較

悪意ノード検出効率が実際の通信性能に対する影響を明らかにするため、異なる悪意ノード数における通信性能の評価をした。車両ネットワークにおいてはユニキャスト通信とブロードキャスト通信の2種類の通信方式があるため、該当結果をそれぞれ図 9と図 10に示している。提案手法をトラスト評価管理なし方式、従来方式と比較した。まず、トラスト評価管理をしない場合のパフォーマンスは非常に低いことが観察できる。また、提案手法は上述のように従来手法より優れた悪意ノード検出効率を持っているため、通信性能も著しく高い。よって、提案トラスト管理手法は悪意ノードが存在する環境においては有効であることが明瞭である。

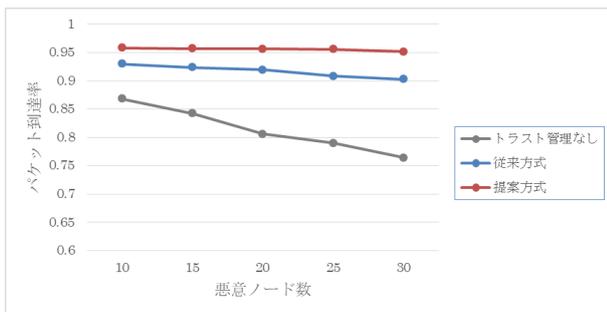


図 9 異なる悪意ノード数におけるパケット到達率の比較 (ユニキャスト通信)

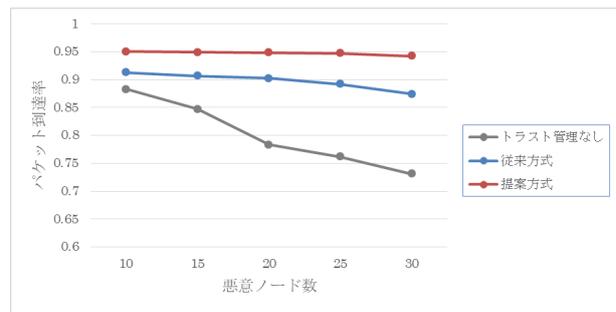


図 10 異なる悪意ノード数におけるパケット到達率の比較 (ブロードキャスト通信)

## 4 研究調査の成果、今後の課題

### 4-1 研究調査成果

本研究では、車両 IoT 向け自己進化型分散トラスト管理手法の提案と評価を行った。2018 年度にはファジィ論理を用いた隣接ノード（車両）トラスト評価手法の設計並びにコンピュータシミュレーション、実証実験による評価を行った。2019 年にはマルチホップネットワークにおける、強化学習を用いて、インダイレクトトラストの確立・更新方法に関する提案と評価を行った。検証結果、提案手法は既存方式に比べてより正確かつ効率的に悪意ノードを検出できることが分かった。また悪意のあるノードが存在環境における通信性能についても評価し、提案手法の有効性を検証した。その結果、提案手法を用いた場合、ユニキャスト通信、ブロードキャスト通信両方において、パケット到達率の著しい向上が実現できることが検証できた。ファジィ論理は人間の思考と似たような近似的な推論を扱うことができ、強化学習は自律分散的にマルチホップ距離におけるトラスト評価を可能とする。ファジィ論理と強化学習の組み合わせで、安定かつ効率的なトラスト評価方式が期待される。さらに、実車両アドホックネットワーク環境において評価し、その実用性を明らかにした。

### 4-2 今後の課題

経済産業省自動走行ビジネス検討会によると、2020 年より順次本格化される自動走行に向けて、高精度な 3D 地図情報をベースに、事故情報や渋滞情報などの動的情報、観光地情報の配信、その他付加的な情報の

データ配信が必要である。このようなアプリケーションを実現するためには自律分散通信を活用できる効率的なネットワーク構造が必要となる。近年、エンドユーザから近いところで計算、キャッシュの配置を行うことでユーザ体感遅延を減らすエッジコンピューティング技術の研究が進められているが、下記の課題がまだ解決されていない：①ブロードキャスト通信，ユニキャスト通信が別々に研究されており，それらの効率的な融合が十分検討されていない；アプリケーション品質要求の多様性が考慮されていない；②ネットワーク環境の複雑性，ノードの分布，通信トラフィックパターンの変化などにより，最適な通信方式と経路の選択を単純な数式モデルで表現できない；既存手法は特定のシナリオにおける通信の最適化を行っているものが多く，ネットワーク環境の変化に追及できる知的制御方式の提案が必要である。

今後の研究では，多様な応用を考慮した高信頼で高効率な自律分散車両エッジ構造の提案と実証実験による評価を行う。高信頼性を実現するためには，本研究のトラスト管理方式を用いることが可能である。さらに，端末の移動，道路状況の変化において素早く対応出来る仕組みを強化するために，今後の研究では，エッジコンピューティング技術と組み合わせ，ファジィ論理を用いて複数の要素を統合的に考慮し，強化学習で教師なし自律分散環境において最適なエッジ構造を構築する。強化学習を利用し，アプリケーション品質要求に合わせた最適なエッジの配置を行うで課題①を解決する。さらに，深層強化学習を用いて，ノードの分布，通信トラフィックパターン，トラスト評価値を考慮した通信経路，通信方式，およびエッジサーバ選択の最適化を行い，知的エッジ構造を構築することで課題②を解決する。

## 【参考文献】

- [1] W. Li and H. Song, "ART: An Attack-Resistant Trust Management Scheme for Securing Vehicular Ad Hoc Networks," *IEEE Transactions on Intelligent Transportation Systems*, vol.17, no.4, pp.960-969 (2016)
- [2] K. Rostamzadeh, H. Nicanfar, N. Torabi, S. Gopalakrishnan, and V. C. M. Leung, "A Context-Aware Trust-Based Information Dissemination Framework for Vehicular Networks," *IEEE Internet of Things Journal*, vol.2, no.2, pp.121-132 (2015)
- [3] C. Wu, S. Ohzahata, Y. Ji, and T. Kato, "How to Utilize Inter-flow Network Coding in VANETs: A Backbone Based Approach," *IEEE Transactions on Intelligent Transportation Systems*, vol.17, no.8, pp. 2223-2237 (2016)
- [4] T. G. Kale, S. Ohzahata, C. Wu, and T. Kato, "Reducing Congestion in the Tor Network with Circuit Switching," *Journal of Information Processing*, vol.23, no.5, pp.589-602 (2015)
- [5] S. Guleng, C. Wu, X. Chen, X. Wang, T. Yoshinaga, and Y. Ji, "Decentralized Trust Evaluation in Vehicular Internet of Things," *IEEE Access*, vol.7, pp.15980 - 15988 (2019)
- [6] The Network Simulator - ns-2, <http://www.isi.edu/nsnam/ns/>, Accessed on Sep. 16, 2017.
- [7] F. Bai, N. Sadagopan, and A. Helmy, "Important: A framework to systematically analyze the impact of mobility on performance of routing protocols for adhoc networks," in *Proc. 22nd Annu. Joint Conf. IEEE Comput. Commun. Soc.*, pp. 825-835, Mar./Apr. 2003.

〈発表資料〉

題名	掲載誌・学会名等	発表年月
Decentralized Trust Evaluation in Vehicular Internet of Things	IEEE Access, vol.7, pp.15980-15988, Jan. 2019.	2019年01月
Spatial Intelligence toward Trustworthy Vehicular IoT	IEEE Communications Magazine, Vol. 56, Issue 10, pp. 22-27, Oct. 2018.	2018年10月
A Context-Aware Edge-Based VANET Communication Scheme for ITS	Sensors, Vol.18, no.7, article no. 2022, June 2018.	2018年06月
Integrating Licensed and Unlicensed Spectrum in Internet-of-Vehicles with Mobile Edge Computing	IEEE Network, vol.33, no.4, pp.48-53, Jul./Aug. 2019.	2019年08月
Multi-Tenant Cross-Slice Resource Orchestration: A Deep Reinforcement Learning Approach	IEEE Journal on Selected Areas in Communications, vol.37, no.10, pp. 2377-2392, Oct. 2019.	2019年10月
Traffic big data assisted V2X communications toward smart transportation	Wireless Networks, vol.26, pp.1601-1610, Nov. 2019.	2019年11月
A VDTN scheme with enhanced buffer management	Wireless Networks, vol.26, pp.1537-1548, Jan. 2020.	2020年01月
Edge-Based V2X Communications With Big Data Intelligence	IEEE Access, vol.8, pp.8603-8613, Jan. 2020.	2020年01月
SDN-based Handover Scheme in Cellular/IEEE 802.11p Hybrid Vehicular Networks	Sensors, vol.20, no.4, article no.1082, pp.1-18, Feb. 2020.	2020年02月
Collaborative Vehicular Edge Computing Towards Greener ITS	IEEE Access, vol.8, pp.63935-63944, Apr. 2020.	2020年04月
Collaborative Learning of Communication Routes in Edge-enabled Multi-access Vehicular Environment	IEEE Transactions on Cognitive Communications and Networking, 11pages, June 2020.	2020年06月