

ニューラルネットワークによる自律分散型 最適無線リソース選択方式とその実装

武田太一^a 黒田多朗^a 長谷川幹雄^{a,b} 村田嘉利^{c,b} 原田博司^b 加藤修三^b

^a 東京理科大学大学院 工学研究科 電気工学専攻

^b 情報通信研究機構 ユビキタスモバイルグループ

^c 岩手県立大学 ソフトウェア情報学部

あらまし 無線通信技術の進歩により、様々な無線ネットワークサービスが実用化されてきた。近年、それらの異なる種類の無線アクセスネットワークを適応的に切り替えながら通信するための垂直ハンドオーバに関する様々な研究、及びその標準化が進められている。本稿では、異種無線ネットワーク間の垂直ハンドオーバが実行可能なネットワーク環境において、自律分散的に無線リソースの利用効率を最適化するハンドオーバ決定方式を提案する。相互結合型ニューラルネットワークの自律型最適化ダイナミクスを応用し、平均スループットの最大化、及び、スループットの平等性（フェアネス）の最適化を試みた。計算機シミュレーションにより、本アプローチによってどちらも最適化可能であることを示した。さらに、IEEE P1900.4 で標準化されているアーキテクチャを利用して提案アルゴリズムを実装し、その動作の有効性を検証した。

Autonomous and Decentralized Optimization of Radio Resource Usage by Neural Network Dynamics and its Implementation

Taichi Takeda^a, Taro Kuroda^a, Mikio Hasegawa^{a,b}, Yoshitoshi Murata^{c,b},

Hiroshi Harada^b, Shuzo Kato^b

^a Department of Electrical Engineering, Faculty of Engineering, Tokyo University of Science

^b Ubiquitous Mobile Communications Group, National Institute of Information and

Communications Technology

^c Faculty of Software and Information Science, Iwate Prefectural University

abstract Various advanced wireless systems have been developed and commercialized. In order to utilize them efficiently by switching among different wireless networks without interruption of an on-going session, vertical handover technologies have been developed and standardized. In order to optimize radio resource usage, we propose an autonomous and decentralized radio resource selection algorithm based on the optimization dynamics of the mutually-connected neural networks. The proposed neural network maximizes the average throughput per terminal and minimizes the differences of the throughput among the terminals at same time by using the fourth-order energy function. We show that the radio resource usage could be optimized by the proposed method based on decentralized and autonomous computing. Furthermore, we have implemented the proposed method using wireless LANs and PCs and confirmed its effectiveness on a real system.

1. はじめに

無線通信技術の進歩により、様々な無線システムが、実用化されている。携帯電話では、第2、第3世代が現在利用されており、第4世代の研究開発も進んでいる。無線LANや、Bluetooth

などの近距離通信用無線システムも広く普及し、さらに、広域パケット通信ネットワークとしてWiMAXの商用サービスも始まろうとしている。

これら様々な種類の無線システムは、それぞれ使用できるエリアや通信速度において、特徴が異

なっている。例えば、携帯電話型のシステムでは、通信エリアが広く、移動時でも利用可能となっているが、無線 LAN などと比較すると、通信速度は劣り、データ通信コストは低いとはいえない。一方、無線 LAN では、通信エリアは狭く、移動に適さないが、通信速度は非常に高速であり、通信コストも低い。そこで、異なる複数の無線アクセスマッシュネットワーク (RAN: Radio Access Network) を、適材適所で自動的に、途切れさせることなく切り換える垂直ハンドオーバを実現するための様々な技術が標準化されている[1,2]。例えば、Mobile IP や IEEE 802.21[3]などを利用することで、異種無線間のスムーズな切り換えが可能となる。IEEE P1900.4[4]では、無線リソースの利用効率を最適化するために必要な様々な情報をネットワーク側と端末側で交換するアーキテクチャが規格化されており、これを利用することで、複数の種類の無線ネットワークを駆使した最適なハンドオーバを実現することが可能となる。

携帯電話や無線 LAN などの異なる無線アクセスマッシュネットワークは、それぞれ管理するオペレータが異なる場合が多い。そのような異種オペレータ間のハンドオーバも考慮した無線リソースの利用効率最適化は、集中管理型で行うのは困難であり、自律分散型の最適化が必要となってくる。自律分散型アルゴリズムを用いると、ユーザ数が増えた大規模なネットワークにおいても、ロードバランシングなどを効率的に行うことができる。これまで、自律分散型の無線リソース選択の最適化アルゴリズムとしては、ゲーム理論をベースとした方式[5,6]や、ニューロンの状態更新によって、最適化を行う手法[7,8]が提案されている。相互結合型ニューラルネットワークを用いた最適化アルゴリズムは、そのエネルギー関数をニューロンの自律分散的な更新によって最小化することが可能なため、分散的な最適化に適している。しかし、文献[7]のアルゴリズムは、結合係数などをパラメータとして求めておらず、集中型の計算が必要となってくる。一方、筆者らは、相互結合型ニューラルネットワークの自律分散型最適化ダイナミクスを利用した、端末の平均スループット最大化アルゴリズムを提案している[8]。このアルゴリズムでは、ホップフィールドの 2 次のニューラルネットワーク[9]を利用し、結合係数、及

び、閾値等のパラメータを事前に導出することによって、自律分散的なスループットの最大化が可能となっている。

このような手法を拡張し、本稿では、ニューラルネットワークダイナミクスを利用したスループットの平等性を最適化するアルゴリズムを提案する。これを最適化する目的関数は、ニューロンの 4 次式となる。しかしながら、従来の相互結合型ホップフィールドニューラルネットワーク[9]は、2 次であり適用できない。そこで、本稿では、高次ニューラルネットワークを導入し、アルゴリズムの実現を行う。さらに、このような提案アプローチを、実際の PC 及び無線 LAN を用いて実現する。IEEE P1900.4 で規格化されている情報交換のためのアーキテクチャを利用し、自律分散的な無線リソースの最適化を行う。

2. 相互結合型ニューラルネットワークを利用した利用したトータルスループットの自律分散型最適化

2.1 相互結合型ニューラルネットワークの概要

相互結合型は、各ニューロンの自律的な状態更新によって、そのエネルギーを減少させ、極小値に収束するという特徴を持っている [10,11]。このような特徴を応用することで、これまで、様々な最適化問題に適用してきた[9]。

各ニューロンの状態 $x_j(t)$ を更新する式としては、他のニューロンからの結合に重みを掛けた以下のような式で与えられる。

$$x_{ij}(t+1) = \begin{cases} 1 & \dots \sum_{k=1}^n \sum_{l=1}^n w_{ijkl} x_{kl}(t) > \theta_{ij} \\ 0 & \dots \text{otherwise} \end{cases} \quad (1)$$

ここで、 w_{ij} はニューロン i とニューロン j との間の結合の重みであり、 θ_i はニューロン i の発火のための閾値、 n はニューロン数である。このようなニューロンを相互に結合したニューラルネットワークは、各ニューロンが式(1)によって自律的に状態更新することによって、システム全体の状態からなるエネルギー関数、

$$E_{2d}(t) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n \sum_{l=1}^n w_{ijkl} x_{ij}(t) x_{kl}(t) + \sum_{i=1}^n \sum_{j=1}^n \theta_{ij} x_{ij}(t) \quad (2)$$

が必ず減少する。すなわち、自律分散型演算によって、システム全体の状態からなるエネルギー関数を最小化することが可能である。

ある最小値探索問題を解く場合、まず、解の状態を 0 と 1 の出力を持つニューロンの状態 $x_{ij}(t)$ で表現し、これを状態変数とする式に問題の目的関数を変換する。次に、ニューロンの状態で定義されたこの目的関数を式(2)のエネルギー関数と比較し、ニューロン間の結合重み w_{ij} 及び閾値 θ_i を算出する。これらの値を用いて、式(1)で状態更新することで、自律分散的に目的の最小値探索問題を解くことができる。ニューロン数が増加（大規模化）しても、システム全体としてのエネルギー関数を最小化させることができることから大規模複雑系を用いた最適化問題に適しているといえる。

2.2 相互結合型ニューラルネットワークダイナミクスによる自律分散型無線リソース最適化

単一オペレータの無線アクセスマッシュネットワークにおいては、ネットワーク側が無線リソースを集中管理的に制御する。しかしながら、複数のオペレータのネットワークを切り換えるながら利用する場合には、分散的な最適化アプローチが必要と考えられる。本研究では、1つ1つの端末における自律分散的な状態更新によって、システム全体を最適化出来るアルゴリズムを、相互結合型ニューラルネットワークの最小化ダイナミクスを利用して実現する。

本章では、まず、全体のキャパシティを自律分散的に最大化する相互結合型ニューラルネットワークについて説明する。ここでは、前提条件として、端末は全ての基地局と接続可能とし、同時に 1 つの基地局にのみ接続して通信することとする。また、ここでは TCP のようなベストエフォートの通信を行うことを想定し、通信キャパシティは、端末間で均等にシェアされるものと仮定する。

この場合、端末 i の利用可能なスループット

$T_i(t)$ は、基地局 j の提供する総スループットを C_j 、基地局 j に接続している端末数を N_j 、端末 i が接続する基地局を $hL(i)$ とすると

$$T_i(t) = \frac{C_{hL(i)}}{N_{hL(i)}} \quad (3)$$

と表せる。よって、最適化問題としての目的関数は、

$$F_1 = \sum_{i=1}^{N_m} T_i(t) = \sum_{i=1}^{N_m} \frac{C_{hL(i)}}{N_{hL(i)}} \quad (4)$$

となる。

このような最適化問題を、ニューラルネットワークダイナミクスを用いて、自律分散的に解くアルゴリズムを構築する。まず、ニューラルネットワークの発火パターンと各端末・基地局との関係を図 1 に示すように設定する。各ニューロンは、端末と基地局との無線リンクに対応しており、端末が基地局に接続する場合を 1(発火)、接続しない場合を 0(非発火)と定義する。

このようにニューロンの状態を用いて定義すると、 F_1 は以下のように変形できる。

$$\begin{aligned} F_1 &= \sum_{i=1}^{N_m} T_i(t) = \sum_{i=1}^{N_m} \frac{C_{hL(i)}}{N_{hL(i)}} \\ &= \sum_{i=1}^{N_m} \frac{C_{hL(i)}}{\sum_{k=1}^{N_m} x_{kL(i)}(t)} \end{aligned} \quad (5)$$

この式では、 $x_{kL(i)}(t)$ が分母にきてしまつており、このままでは式(2)のような形に変形できない。そこで、式(5)を最大化するという目的関数を、その逆数を最小化させるという問題におきかえる。すると、エネルギー関数は、

$$\begin{aligned} E_1 &= \sum_{i=1}^{N_m} \frac{1}{T_i(t)} = \sum_{i=1}^{N_m} \frac{\sum_{k=1}^{N_m} x_{kL(i)}(t)}{C_{hL(i)}} \\ &= \sum_{i=1}^{N_m} \sum_{j=1}^{N_{AP}} \sum_{k=1}^{N_m} \frac{1}{C_j} x_{ij}(t) x_{kj} \\ &= \sum_{i=1}^{N_m} \sum_{j=1}^{N_{AP}} \sum_{k=1}^{N_m} \sum_{l=1}^{N_{AP}} \frac{1}{C_j} (1 - \delta_{ik}) x_{ij}(t) x_{kj} \\ &\quad + \sum_{i=1}^{N_m} \sum_{j=1}^{N_{AP}} \frac{1}{C_j} x_{ij}(t) \end{aligned} \quad (6)$$

のようになる。ここで、 δ_{ij} はクロネッカー

デルタである。

$$\delta_{ij} = \begin{cases} 1 & \cdots i=j \\ 0 & \cdots i \neq j \end{cases} \quad (7)$$

式(2)と式(6)の係数比較をすると、ニューロン間の結合重み W_{jkl}^A と閾値 θ_{ij}^A が以下のように得られる。

$$W_{jkl}^A = -2 \frac{1}{C_j} (1 - \delta_{ik}) \delta_{jl} \quad (8)$$

$$\theta_{ij}^A = \frac{1}{C_j} \quad (9)$$

このようなニューラルネットワークを用いて自律分散的に基地局選択を行った結果を図 2 に示す。ニューラルネットワークを用いた手法を、

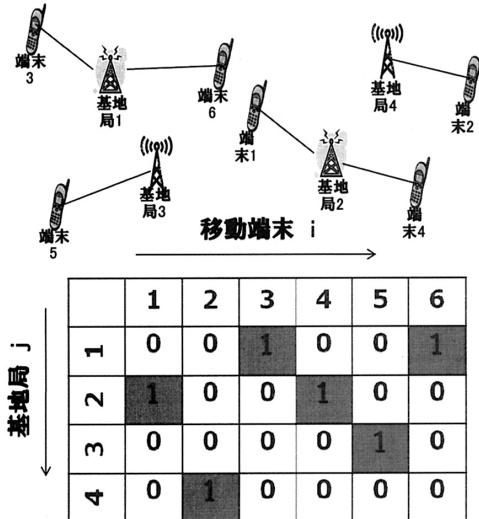


図 1 ニューラルネットワークの発火パターンと各端末・基地局の接続関係

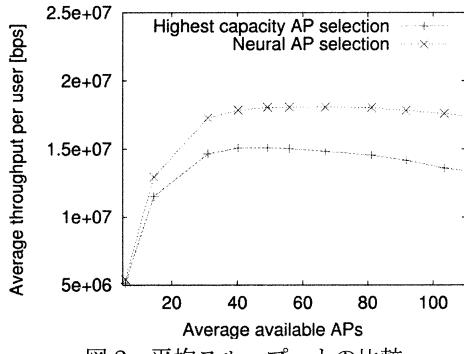


図 2 平均スループットの比較

接続可能な基地局の中から最もキャパシティが大きいものに接続するというロードバランシングを考慮した選択方法と比較している。図 2 より、筆者らが提案したアルゴリズムによって全体のキャパシティを改善できたことが示せる。

3. 高次積結合ニューラルネットワークのダイナミクスに基づいたフェアネスの自律分散型最適化

3.1 フェアネスの最適化問題と高次元の目的関数

2.2 に記した方法で、自律的に最大のスループットを得るようにロードバランシングさせることができる。しかし、最大スループットを得るようには基地局へ接続するため、端末あたりのスループットに偏りが出てくる。そこで、本稿では、トータルスループットを最大にすることを考慮しつつさらに、端末あたりのスループットの格差を最小化する方法について検討する。2.2 と同様に式(3)の逆数を取り、

$$\frac{1}{T_i(t)} = \frac{\sum_{m=1}^{N_m} x_{mL(i)}(t)}{C_{hL(i)}} = \sum_{m=1}^{N_m} \sum_{j=1}^{N_{Ap}} \frac{1}{C_j} x_{mj} x_{ij} \quad (10)$$

を用いることとすると、複数の端末における格差は、

$$E_2 = \sum_{i=1}^{N_m} \sum_{k=1}^{N_m} \left(\frac{1}{T_i(t)} - \frac{1}{T_k(t)} \right)^2 \quad (11)$$

となり、これを最小化すればよいことになる。ところが、この式(11)では、スループットが大きく改善するように状態更新をする場合、スループットの差自体である E_2 の値も大きくなってしまう。そのため、このエネルギー関数をベースにしてニューラルネットワークを構築すると、スループットが大きく改善するような状態更新を行い、発火が起これにくくなり、小さいものを優先に接続してしまうこととなる。そこで、ここでは、キャパシティの逆数の端末平均 $R_i(t)$ を均等にしていく問題に転換して考える。ここで、

$$R_i(t) = \frac{1}{C_{hL(i)}} \frac{1}{N_{hL(i)}} \quad (12)$$

とすると、その逆数は、

$$\frac{1}{R_i(t)} = \sum_{m=1}^{N_m} C_{hL(i)} x_{mL(i)}(t) = \sum_{m=1}^{N_m} \sum_{j=1}^{N_{Ap}} C_j x_{mj} x_{ij} \quad (13)$$

のように、ニューロンの状態 $x_{mL(i)}(t)$ の関数で記述できる。この差を最小化するエネルギー関数は、

$$E_2' = \sum_{i=1}^{N_m} \sum_{k=1}^{N_m} \left(\frac{1}{R_i(t)} - \frac{1}{R_k(t)} \right)^2 \quad (14)$$

となり、この式(14)に式(13)を代入し展開すると、エネルギー関数は、

$$E_2' = \sum_{i=1}^{N_m} \sum_{k=1}^{N_m} \sum_{m=1}^{N_m} \sum_{j=1}^{N_m} \sum_{n=1}^{N_m} \sum_{l=1}^{N_m} C_j C_l (x_{mj} x_{ij} x_{nl} x_{il} - 2x_{mj} x_{ij} x_{nl} x_{kl} + x_{mj} x_{kj} x_{nl} x_{kl}) \quad (15)$$

となる。

3.2 相互結合型ニューラルネットワークのエネルギー関数の高次元化

式(6)の E_1 は、2 次のエネルギー関数であるため、式(1)の状態更新式と式(2)のエネルギー関数に基づいた最適化を行うことが可能であった。しかし、式(15)の E_2' は、4 次のエネルギー関数であるため、従来から用いられている式(2)のホップフィールドニューラルネットワークのエネルギー関数を利用することができない。そこで、本研究では、Cooper によって定式化された高次の積結合をもつ Higher-Order Neural Network を用いることとする[12]。

3 次の Higher-Order Neural Network の状態更新式は、

$$x_{ij}(t+1) = \begin{cases} 1 & \dots \frac{1}{6} \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} \\ & \sum_{m=1}^{N_m} \sum_{n=1}^{N_m} \sum_{o=1}^{N_m} \sum_{p=1}^{N_m} U_{ijklmnop} x_{kl}(t) x_{mn}(t) x_{op}(t) \\ & + \frac{1}{2} \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} \sum_{m=1}^{N_m} \sum_{n=1}^{N_m} V_{ijklmn} x_{kl}(t) x_{mn}(t) \\ & + \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} W_{ijkl} x_{kl}(t) > \theta_{ij} \\ 0 & \dots \text{otherwise} \end{cases} \quad (16)$$

のようになる。他のニューロンからのシナプス結合が 1 次から 3 次までの積の形で導入されている。これを自律分散的に状態更新していくことで、最小化されるエネルギー関数は、

$$\begin{aligned} E_{4d} = & -\frac{1}{24} \sum_{i=1}^{N_m} \sum_{j=1}^{N_m} \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} \sum_{m=1}^{N_m} \sum_{n=1}^{N_m} \\ & \sum_{o=1}^{N_m} \sum_{p=1}^{N_m} U_{ijklmnop} x_{ij} x_{kl} x_{mn} x_{op} \\ & -\frac{1}{6} \sum_{i=1}^{N_m} \sum_{j=1}^{N_m} \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} \sum_{m=1}^{N_m} \sum_{n=1}^{N_m} V_{ijklmn} x_{ij} x_{kl} x_{mn} \\ & -\frac{1}{2} \sum_{i=1}^{N_m} \sum_{j=1}^{N_m} \sum_{k=1}^{N_m} \sum_{l=1}^{N_m} W_{ijkl} x_{ij} x_{kl} - \sum_{i=1}^{N_m} \sum_{j=1}^{N_m} \theta_{ij} x_{ij} \end{aligned} \quad (17)$$

のように、ニューロン状態が 4 次式となる。この式を利用してすることで、式(15)の最適化問題を解くことができる。

3.3 フェアネスを考慮した無線リソース最適化のためのエネルギー関数と結合重みと閾値の導出

式(15)において、ニューラルネットワークの自己結合項を除去し、式(17)のエネルギー関数と係数比較をすると、結合重み、閾値である $U_{ijklmnop}^B$ 、

$$V_{ijklmn}^B, W_{ijkl}^B, \theta_{ij}^B$$

$$\begin{aligned} U_{ijklmnop}^B = & -[\{2(\delta_{ik}-1)C_j C_l + 2(\delta_{lo}-1)C_j C_p \\ & + 2(\delta_{km}-1)C_l C_n + 2(\delta_{mo}-1)C_n C_p\} \delta_{jn} \delta_{lp} \\ & - \{2(\delta_{im}-1)C_j C_n + 2(\delta_{lo}-1)C_j C_p \\ & + 2(\delta_{km}-1)C_l C_n + 2(\delta_{ko}-1)C_l C_p\} \delta_{jl} \delta_{np} \\ & - \{2(\delta_{ik}-1)C_j C_l + 2(\delta_{im}-1)C_j C_n \\ & + 2(\delta_{ko}-1)C_l C_p + 2(\delta_{mo}-1)C_n C_p\} \delta_{jp} \delta_{ln}] \end{aligned} \quad (18)$$

$$\begin{aligned} V_{ijklmn}^B = & -[C_j C_l \{\delta_{im} \delta_{ln} + \delta_{km} \delta_{jn} - 5(\delta_{jn} + \delta_{ln}) \\ & + 3(\delta_{ik} \delta_{jn} + \delta_{ik} \delta_{ln}) - 10 \delta_{ji} \delta_{jn}\} \\ & + C_j C_n \{\delta_{ik} \delta_{ln} + \delta_{km} \delta_{jl} - 5(\delta_{jl} + \delta_{ln}) \\ & + 3(\delta_{im} \delta_{jl} + \delta_{im} \delta_{ln}) - 10 \delta_{jl} \delta_{jn}\} \\ & + C_l C_n \{\delta_{ik} \delta_{jn} + \delta_{im} \delta_{jl} - 5(\delta_{jl} + \delta_{jn}) \\ & + 3(\delta_{km} \delta_{jl} + \delta_{km} \delta_{jn}) - 10 \delta_{jl} \delta_{jn}\}] \end{aligned} \quad (19)$$

$$W_{ijkl}^B = -2C_j C_l (16\delta_{jl} - 2\delta_{ik} + 2) \quad (20)$$

$$\theta_{ij}^B = -10C_j C_l \quad (21)$$

のようになる。これらを、式(16)を用いて更新することにより、自律分散的にスループットのフェアネスの最適化を行なうことが可能となる。

トータルスループットの最大化を考慮しつつフェアネスを最適化する自律分散型最適化問題を解くために、両者を含んだエネルギー関数を以下のように定義する。

$$E = AE_1 + BE_2' \quad (22)$$

ただし、式(22)において A 、 B はそれぞれのエネルギー関数の重みである。この E を最小化するための結合重み及び閾値は、以下のようなになる。

$$U_{ijklmnop}^{TOTAL} = BU_{ijklmnop}^B \quad (23)$$

$$V_{ijklmn}^{TOTAL} = BV_{ijklmn}^B \quad (24)$$

$$W_{ykl}^{TOTAL} = AW_{ykl}^A + BW_{ykl}^B \quad (25)$$

$$\theta_{ij}^{TOTAL} = A\theta_{ij}^A + B\theta_{ij}^B \quad (26)$$

これらを用いて式(16)を更新していくことで、トータルスループットとフェアネスを考慮した最適化問題を解くことが可能となる。本稿では、各端末は、同時に 1 つの基地局としか接続しないと仮定するため、ニューロンでいえば、各端末に対応する N_{AP} 個のニューロンのうち 1 つのみが発火すればよい。そこで、文献[13]で提案されている最大発火検出による発火判定法を導入し、状態更新式を以下のようにする。

$$x_{ij}(t+1) = \begin{cases} 1 & \dots y_{ij}(t+1) = \max \{y_{i1}(t+1), \\ & \dots, y_{iN_{AP}}(t+1)\} \\ 0 & \dots \text{otherwise} \end{cases} \quad (27)$$

ただし、

$$\begin{aligned} y_{ij}(t+1) = & \frac{1}{6} \sum_{k=1}^{N_m} \sum_{l=1}^{N_{AP}} \\ & \sum_{m=1}^{N_m} \sum_{n=1}^{N_{AP}} \sum_{o=1}^{N_m} \sum_{p=1}^{N_{AP}} U_{ijklmnop} x_{kl}(t) x_{mn}(t) x_{op}(t) \\ & + \frac{1}{2} \sum_{k=1}^{N_m} \sum_{l=1}^{N_{AP}} \sum_{m=1}^{N_m} \sum_{n=1}^{N_{AP}} V_{ijklmn} x_{kl}(t) x_{mn}(t) \\ & + \sum_{k=1}^{N_m} \sum_{l=1}^{N_{AP}} W_{ykl} x_{kl}(t) - \theta_{ij} \end{aligned} \quad (28)$$

である。

4. シミュレーションによる評価及び比較

基地局数を 10 として固定、端末数を増やしていくときの各端末あたりの平均スループットを図 3 に、分散を図 4 にそれぞれ示す。ここでは、トータルスループット最大化のみを考慮した場合($B=0$)とフェアネスを考慮した場合とを比較する。ここで、フェアネスを最適化する場合は式(22)のエネルギー関数の重みを、端末数を変えるごとに最適に選んだものとする。各基地局の提

供するトータルスループットは、 $2 \cdot 2 \cdot 10 \cdot 10 \cdot 10 \cdot 10 \cdot 18 \cdot 18 \cdot 24 \cdot 24$ Mbps とする。また、本実験結果は、ランダムな 500 個の初期値を用いて計算した時の平均を取ったものである。

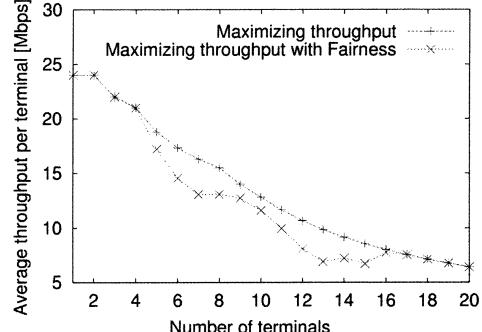


図 3 平均スループットの比較

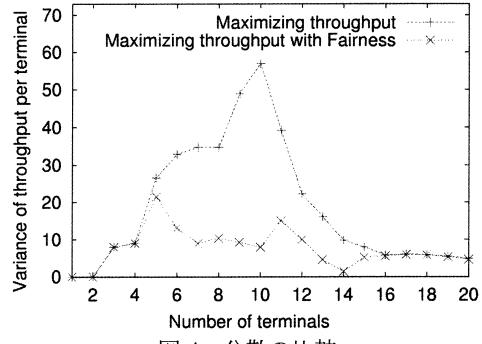


図 4 分散の比較

図 4 より、フェアネスを考慮した場合、トータルスループットのみの場合より大幅に分散値を減少させることができた。特に基地局数 10 に対し、端末数 10 あたりのところでは 6 分の 1 ほどスループットの分散を抑えることができた。一方、図 3 より、平均スループットの方は、フェアネスを考慮した場合は、その値を 10% 程度下げる結果となった。ネットワーク全体としてみると端末数当たりの使用スループットを若干下げる結果となるが、その分スループットの平等性はかなり改善できたといえる。エネルギー関数の重み A 、 B を調節することで、ネットワークの管理側、もしくは、ユーザ側のニーズに応じてスループット重視、あるいは、フェアネス重視かを、決めることができる。

5. ニューラルネットワークダイナミクスに基づいた無線リソース最適化アルゴリズムの実装

本稿では、これらのアルゴリズムが実際に動作するかを検証するうえで、IEEE P1900.4 で標準化が進められているアーキテクチャ上にて実装することを試みる。

5.1 IEEE P1900.4 の概要

SCC41 (Standards Coordinating Committee 41) の IEEE P1900.4 ワーキンググループでは、異なる RAN にまたがって、無線リソースを最適に利用するために、RAN や端末で取得される様々な情報を交換する方式が規格化されている。ダイナミックスペクトルアクセスや自律分散的なハンドオーバによって、ネットワーク側と端末側との間、あるいは、ネットワーク側のエンティティ同士で情報交換する。RAN の情報は、ネットワーク側に設置される Network Reconfiguration Manager (NRM) に集められる。端末側の情報は、Terminal Measurement Collector (TMC) が取得し、Terminal Reconfiguration Manager (TRM) に集められる。そして、Radio Enabler (RE) という論理的な共通シグナリングネットワークを経由してネットワーク側の NRM と端末側の TRM との間で情報がやり取りされる。

5.2 システム構成とアルゴリズムの実装

コグニティブワイヤレスクラウド (Cognitive Wireless Clouds: CWC) [14,15] は、IEEE P1900.4 の仕様に沿って設計されている。本研究では、文献[16]で報告されている CWC システムをベースに、アルゴリズムの実装を行う。

上記のシミュレーションと同様、各ニューロンを端末と基地局との間の無線リンクに対応させる。TRM は、NRM が収集した無線リンクの接続情報を、RE を経由して取得する。これらの接続・非接続の情報より、ニューラルネットワークの発火情報を取得し、自端末の接続に関連するニューロンの状態更新を、それぞれの端末上で行う。ニューロンの発火状態に基づいて、各端末が自律分散的に最適な基地局を選択する。

本システムの構成を図 5 に示す。端末としては、

ノート PC7 台、NRM1 台、モビリティマネージャ 4 台を用いて、実際に無線 LAN と PHS を利用して実験した。提案アルゴリズムが、このような構成によって動作し、各端末が自律的にハンドオーバすることを確認した。

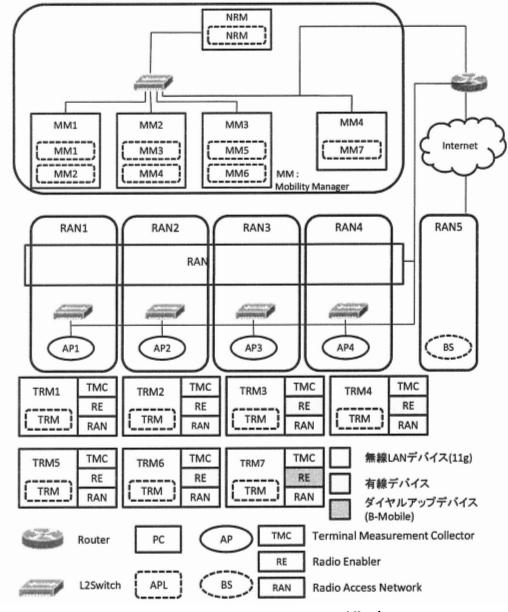


図 5 CWC システム構成

6. まとめ

本論文では、ヘテロジニアスな無線ネットワーク環境において、4 次のニューラルネットワークを用いて、自律分散的に各端末の使用スループットの格差を最小化するというアルゴリズムを提案した。シミュレーションによる評価により、本提案手法がフェアネスを最適化可能であることが示せた。

さらに、本アルゴリズムを IEEE P1900.4 のアーキテクチャを利用して実装し、その動作を確認した。今後は、高速ハンドオーバやマルチリンクアグリゲーション等を考慮し、本アプローチを拡張していく。

参考文献

- [1] G. Wu, P. Havinga and M. Mizuno, "MIRAI Architecture for Heterogeneous Networks," IEEE Comm. Mag., pp. 126–134, 2002.
- [2] M. Inoue, D. Mahmud, H. Murakami, M. Hasegawa and H. Morikawa, "Novel

- Out-Of-Band Signaling for Seamless Interworking between Heterogeneous Networks," IEEE Wire Commun., Vol. 11, No. 2, pp. 56–63, 2004.
- [3]G. Lampropoulos, A. Salkintzis and N. Passas, "Medc is-Independent Handover for Semless Service Provision in Heterogeneous Networks," IEEE Communications Magazine, Vol. 46, No. 1, Jan. 2008.
- [4]S. Buljore, M. Muck, P. Martigne, P. Houze, H. Harada, K. Ishizu, O. Holland, A. Mihailovic, K. A. Tsagkaris, O. Sallent, G. Clemo, M. Sooriyabandara, V. Ivanov, K. Nolte, M. Stametalos, "Introduction to IEEE1900.4 Activities," IEICE Trans. On Communications, Vol. 91-B, No. 1, pp. 2-9, 2008.
- [5]山田武史, 浅井孝浩, 古野辰男, 大矢智之, “コグニティブ無線におけるシステム間・ユーザ間公平性を実現する自律分散制御法,” 電子情報通信学会, 技術研究報告, SR2007-13, pp.73-78.
- [6]J. Neel, J. Reed, and R. Gilles, "Convergence of cognitive radio networks," Proc. IEEE Wirel. Commun. Netw. Conf., pp.2250-2255, March 2004.
- [7]D. Gomez-Barquero, D. Calabuig, J. Monserrat, N. Garcia, and J. Perez-Romero, "Hopfield Neural Network-based Approach for Joint Dynamic Resource Allocation in Heterogeneous Wireless Networks," Proc. of IEEE Vehicular Technology Conference, 2006.
- [8]M. Hasegawa, H. N. Tran, G. Miyamoto, Y. Murata, H. Harada, "Autonomous and Decentralized Optimization of Large-Scale Heterogeneous Wireless Networks by Neural Network Dynamics," IEICE TRANS. COMMUN., Vol. E91-B, No. 1, pp.110–118, January, 2008.
- [9]J. J. Hopfield and D. W. Tank, "Neural Computation of Decisions in Optimization Problems," Biological Cybernetics., Vol. 52, No. 3, pp. 141-152, 1985.
- [10]J. J. Hopfield, "Neural Networks and Physical Systems with Emergent Collective Computational Abilities," Proc. Natl Acad. Sci. USA, Vol. 79, pp. 2554-2558, 1982.
- [11]J. J. Hopfield, "Neurons with Grade Response Have Collective Computational Properties like Those of Two-State Neurons," Proc. Natl Acad. Sci. USA, Vol. 81, pp. 3088-3092, 1984.
- [12]B. S. Cooper, "Higher order neural networks-Can they help us optimise?," Proc. Sixth Australian Conf. on Networks (ACNN '95), pp.29-32, 1995.
- [13]Y. Takefuji, K. Lee and H. Aiso, "An artificial maximum neural network: a winner-take-all neuron model forcing the state of the system in a solution domain," Biological Cybernetics, Vol. 67, No. 3, 1992.
- [14]H. harada, H. Murakami, K. Ishizu, S. Filin, Y. Saito, H. Tran, G. Miyamoto, M. Hasegawa, Y. Murata, and S. Kato, "A Software Difined Cognitive Radio System: Cognitive Wireless Cloud," IEEE Globecom 2007, Washington, USA, Nov. 2007.
- [15]長谷川幹雄, 原田博司, 加藤修三, ユビキタスモバイル通信実現に向けての研究開発, 第5回MWPワークショップ, pp. 23-45, 2007年4月.
- [16]K. Ishizu, H. Murakami, G. Miyamoto, H. N. Tran, S. Filin, M. Hasegawa, Y. Murata, H. Harada, S. Kato, "Design and Implementation of Cognitive Wireless Network based on IEEE P1900.4," Proc. of IEEE Sensor, Mesh and Ad Hoc Communications and Networks Workshops, 2008.