

平成30年6月16日現在

機関番号：12601

研究種目：挑戦的萌芽研究

研究期間：2016～2017

課題番号：16K12405

研究課題名(和文) データ処理とエネルギーの時空間上制御モデルの研究

研究課題名(英文) Spatial and Temporal Control of Data Processing and Energy Consumption

研究代表者

中村 宏 (NAKAMURA, HIROSHI)

東京大学・大学院情報理工学系研究科・教授

研究者番号：20212102

交付決定額(研究期間全体)：(直接経費) 2,600,000円

研究成果の概要(和文)：データに対して処理すべき内容と利用可能なエネルギーが状況に応じて大きく変動する、広域分散センシング・コンピューティングにおいて、時空間上でのデータ処理を最適化する実行モデルを提案した。まず、処理タスクの実行時間が実行時に決定する場合に、性能制約を満たしつつ消費エネルギーを最小化するタスクスケジューリングを提案し、既存手法に対する有効性を示した。次に、収集可能な電力が環境に応じて変動するエネルギーハーベスティングセンサーノードにおいて、設置場所によらず収集した電力を浪費することなく高い性能を達成できる動作スケジューリングを、強化学習を用いることで実現し、その有効性を示した。

研究成果の概要(英文)：Data processing and available energy heavily depend on environments in widely distributed sensing and computing systems. This research proposed execution model which optimize data processing both in temporal and spatial in such systems. Firstly, in case that processing time of task is determined during computation, task scheduling algorithm is proposed to minimize energy consumption while satisfying performance constraints. Its superiority to other existing methods is successfully shown. Secondly, in solar energy harvesting sensor node systems, an adaptive power manager is proposed by using reinforcement learning. The proposed manager successfully achieves higher performance without increasing wasted energy regardless the location of sensor nodes.

研究分野：計算機アーキテクチャ

キーワード：コンピューティング 低消費エネルギー 実行モデル スケジューリング

1. 研究開始当初の背景

センシング技術の進歩にともない、1兆個のセンサーを使用する社会「Trillion Sensors Universe」が到来し、広域に分散されたあらゆる物にセンシングとコンピューティング機能を持つノードが搭載されインターネットにつながるIoT(Internet of Things)社会が実現されようとしており、物理世界と情報世界がインタラクションするサイバーフィジカルシステムへの期待が高まっている。このようなシステムでは、各センサーノードには性能制約が存在し、処理をいつまでに終了させるべきかというデッドラインが与えられていることが多い。また、各センサーノードはバッテリーを有し情報の処理に必要なエネルギーを周囲の環境から得る(エネルギーハーベスティング)必要があることも多い。そのため、消費エネルギー当たりの処理量(エネルギー効率)を向上させるだけではなく、性能制約を満たしつつ、個々のノードにおいて利用可能なエネルギー量に応じてシステムとして機能を提供し続ける必要がある。しかし、これまでの情報システムの低電力化技術は基本的にエネルギー効率を向上させる手法であった。

2. 研究の目的

本研究では、広域に分散されたセンシング・コンピューティングシステムを対象とする。前節で述べたように、そのようなシステムでは、処理内容に応じて処理時間が変動する場合でもデッドライン制約を満たす、あるいは電源供給が不安定で利用可能なエネルギーが変動する場合でもできるだけ長い処理時間を実現しシステムとしての可用性を向上することが重要となる。その実現のために、時空間上で処理の制御を行う実行モデルを提案する。この研究の目的は、提案する実行モデルによって、物理的に分散されたセンシング・コンピューティング環境で、システム全体の飛躍的な低電力化と高可用性を実現できることを明らかにすることである。

3. 研究の方法

(1)処理内容に応じて処理時間が変動する場合でもデッドライン制約を満たすような処理の実行モデルの研究として、ニアリアルタイム(Near-Real Time)処理、および、GPS衛星からの位置情報追跡システムの2つの問題に取り組んだ。いずれも、システムに固有な、処理時間と消費電力の関係を予め定式化しておく。その上で、この関係式が与えられたときに最適な処理スケジューリングを実現する実行モデルを構築する。次節では、この中のニアリアルタイム処理問題の成果を詳述する。また、(2)電源供給が不安定で利用可能なエネルギーが変動する場合でもできるだけ長い処理時間を実現しシステムとしての可用性を向上する研究として、環境発電駆動センサーノードの適応型電力制御

問題、に取り組んだ。この問題では、強化学習を用いて、発電電力量をもとに、センサーノードのセンシング間隔を動的に制御する。

4. 研究成果

(1)ニアリアルタイム処理:リアルタイム処理においては、処理が起動されてから終了するまでの時間に制約(デッドライン)が存在する。ニアリアルタイム処理とは、処理が周期的に発生し、各処理のデッドラインが、処理が発生する周期より長い問題のことであり、画像処理をはじめとして現実の世界では一般的な問題設定である。また、物理世界のデータを扱う処理、これも画像処理が代表的であるが、においては、入力データに応じて必要となる処理量に変動が生じる。このような問題に対する従来手法としては、図1の(a)Fixedに示すスケジューリングが代表的である。すなわち、デッドラインと周期を同一と考え、1周期内で必ず処理が終了するように、プロセッサを動作させる。この場合、処理が重たい場合(図中ではDと表記)の場合、プロセッサを高性能モードで動作させることでデッドラインが守れる。しかし、処理が軽い場合(図中ではAと表記)には、デッドラインに対し余裕をもって処理が終了してしまい、理想的にはより低性能で動作させることで低消費電力化が可能な筈である。この理想的な動作を実現したものが(b)Oracle Frame-basedである。しかし、Aの処理が軽いかどうか、は実行してみないとわからないため、現実的にはこの実行制御は不可能である。それに対し、(c)Proposedに示す提案手法では、デッドラインが周期より長いことを利用し、さらに、実行中にデッドラインまでの余裕時間を考慮しながらプロセッサの動作モードを変更させる(図中では、動作モードの変更は発生していない)。また、一般に動作モード変更時にエネルギーオーバーヘッドが生じるが、この制御では、その得失利害も考えて動作モードを選択する。

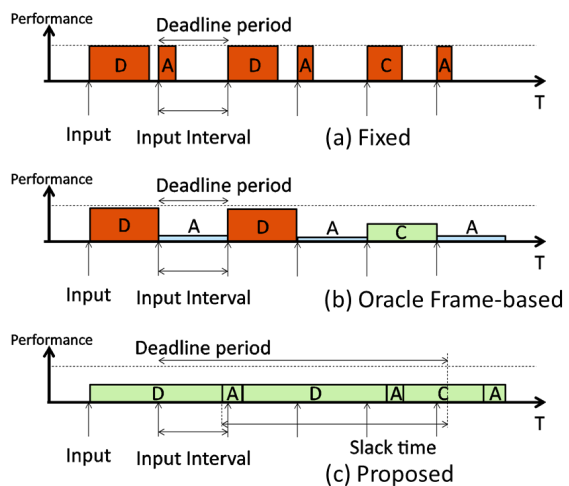


図1: ニアリアルタイム処理における従来手法と提案手法におけるスケジューリング

評価結果を図2に示す。この評価では、提案手法をH.264デコーダに適用した。有効性は対象とする処理の重さに依存するので、評価では3種類の動画を用いた。図中では、ani, high, lowと表記しており、それぞれ、アニメーション、動きが大きい動画、動きが小さい動画を表す。また、各処理において、最大の処理量は既知としている。これは、あらかじめ最悪実行時間がわかっているという妥当な仮定である。3種類の動画、いずれの場合もサンプリング間隔は50msで固定とした。動画の各カテゴリー内で、棒グラフが6本あるが、上の2本は、図1の(a)Fixed、および、(b)Oracle Frame-basedを適用したものである。また、Proposedについては、デッドライン(図中ではd=)を250ms, 500ms, 1000ms, Inf(無限大)と設定した。Infでは、デッドライン制約がないことと等価である。また、プロセッサには、最も高性能だが消費電力が大きいモード(Mode4)から、最も性能は低い消費電力も小さいモード(Mode1)までの4段階の電力モードがあると仮定している。




図2 : H.264 デコーダに適用したときの評価結果

図2の結果から以下のことがわかる。まず、Fixedスケジューリングでは、負荷が軽い処理に対しても低電力モードに移行することができず、常に、消費電力の大きい電力モードが選択されている。早く処理が終わった場合には、次のデータが入力されるまでプロセッサはsleepモードになるが、電力モード移行に伴うオーバーヘッド電力も無視できないほど多い。次に、(b)Oracle Frame-basedは、(a)Fixedに対してかなりの低電力化を達成できるが、この低電力化は、実行前に各入力に対する処理負荷量が既知であるという非現実的な仮定を置いているから実現できるものであり、実際には実現できない。これらに対し、提案する(c)Proposedは、デッドライン制約がサンプリング周期よりも長いことを活用できるため、実行前に各サンプリングに対する処理量が未知であるにもかかわらず、実行時に適切な電力モードを選択することができ、低電力化を達成できている。ani(アニメーション動画の場合)でd=1000ms(デッドライン制約が1000msの場合)で、(b)に対して約10%の低電力化を実現できている。デッドライン制約が短い場合(図中で

はd=250msの場合に相当)は、選択している低電力モードではデッドライン制約を満たせない状況が多く発生するため、高性能かつ高消費電力モードに移行する頻度が高くなり、overhead電力も大きくなることもわかる。

(2)環境発電駆動センサーノードの適応型電力制御問題:太陽光発電などの環境発電により駆動するセンサーノードでは、バッテリー切れによる動作停止を防ぎつつ、発電電力に応じてセンシング間隔を調整するなどの電力制御を行う必要がある。つまり、環境発電駆動センサーノードでは、エネルギー消費を最小化することではなく、発電した電力を利用していかに高い性能を発揮させるかに目的が変化する。そこで、エネルギー消費と発電されたエネルギーが等しい状態を意味するエネルギー中立性(energy neutrality)を保ちつつ、最大限にノードの性能を引き出すENO-Maxを達成することが重要となる。しかし、発電電力やバッテリー容量などには限界があり、さらに、環境発電においては発電電力は時間により変動するため、安定した電力供給が得られるわけではないという課題もある。本研究では、ENO-Max条件を達成するために、センサーノードのデューティサイクル(duty cycle:実際に動作する時間)を調整する問題としてモデル化を行った。デューティサイクルの調整に関しては、これまでも多くの研究が行われている。例えば、発電されるエネルギー量を予測してデューティサイクルを調整しエネルギー中立性の達成を試みるもの[Kansalの手法]、線形2次トラッカーを利用するものなどが提案されている。しかしながら、これらの手法では設置された環境やバッテリー容量、プロセッサの消費電力など、システムの仕様に応じていくつかのパラメータを調整しつつ運用することが必要であり、多種多様な1兆個にも及ぶセンサーが様々な環境下で利用されると予想される将来のIoT社会で、全てのセンサに対してパラメータを調整することは現実的ではない。そこで、本研究ではENO-Max条件を達成するためのより汎用的な手法として、強化学習を用いた手法を提案した。強化学習は、学習器が一連の行動によりもたらされる結果を探索し、将来にわたり得られる報酬の合計が最大となるような行動を学習フェーズで記録する。その上で、実行段階では、学習結果に基づき得られる報酬が最大となる行動を状況に応じて選択する。なお、本研究期間内では、太陽光発電を利用したセンサーノードに限定した検討を行ったが、提案するモデルは、他の環境発電にも適用可能であり、手動での最適なパラメータ設定の手間を最小化しつつ、環境から得られるデータを基にENO-Max条件を達成し、また環境の違いにも適応的に対応できることが期待される。

モデリング対象のシステムを図3に示す。図に示すように、環境発電エネルギー源、バッテリー、エネルギーを消費する側のセンサーノード、そして電力管理ユニット、の4つの構成要素からなるモデルを検討する。センサーノードのデューティサイクルは可変であり、デューティサイクルを上げることで性能が高くなる。




図3：対象システムのモデル

強化学習は、経験から学ぶことをベースとした機械学習の一手法であり、システムが種々の行動から最適と考えられる行動を自動で選択することが可能となる。目的に合致する行動をすると報酬が与えられ、合致しない行動の場合には罰が与えられる。試行錯誤を繰り返すことで、学習により長期的な報酬を最大化するような行動をシステムが選択することが可能となる。

Q学習(Q-learning)は強化学習のアルゴリズムの一つであり、各状態と行動のペアに対してQ値を割り当て、それをQテーブルに保存する。ある状態と行動のペア(s,a)のQ値は、状態sを開始点として最初の行動として行動aを選択した場合に得られる割引を加味した報酬の和の最大値と定義される。言い換えると、ある状態と行動のペア(s,a)のQ値は、状態sから開始して行動aを選択し、その後は最良の方策にしたがって行動した場合の合計の報酬の期待値となる。

Q学習において、Greedy法では、エージェントは現在のQテーブルの情報をもとに常にQ値が最大の行動を選択する。そのため、Q値が最適な値に収束していない場合には、局所最適な行動のみを選択してしまう。一方、大規模なQテーブルの場合、多数の試行錯誤を繰り返したとしても収束させることは難しい場合も存在する、そこで、エージェントは一定の確率でランダムに行動を選択し、他の行動の価値を探索する。Greedy法も提案されている。この手法の利点は、経験を積む毎により多くの行動が複数回にわたって評価されることになり、局所最適な状態になることを防ぐことである。

評価に用いたシステムの仕様は以下のとおりである。

- ・エネルギー源：太陽光パネルを持つセンサーノードを想定し、気象庁のウェブサイト(<http://www.jma.go.jp>)より全天日射量デ

ータを取得して、発電エネルギー量を計算した。このデータには、国内のいくつかの場所について、1時間当たりの全天日射量が保存されている。そこで、評価ではこのデータに合わせ、エポックは1時間とした。

- ・センサーノード：指定したデューティサイクルに応じてエポックあたり50mWhから500mWhのエネルギーを消費すると仮定した。デューティサイクルは10%, 20%, ..., 100%のように、10%刻みで設定可能とした。

- ・バッテリー：容量が20000mWhで理想的な特性を持つと仮定し、round-trip効果や漏れ電流、時間経過にともなうバッテリーの劣化は考慮しない。充電ロスや漏れ電流は、ノードにおける余分な消費エネルギーと見なすことが可能である。

電力管理による実行制御方式の評価として、2つの従来手法と提案手法での比較を行う。従来手法の1つ目はNaiveな手法であり、バッテリー残容量が下限の閾値を下回った場合は最も低いデューティサイクルへ、上限の閾値を上回った場合は最も高いデューティサイクルへ、その中間であればバッテリー残容量に比例するデューティサイクルを利用するものである。2つ目はKansalらによる従来研究をベースとしたもので、1日の合計発電エネルギー量を予測し、その情報をもとにエネルギー中立性が確保されるように一日を通して一定のデューティサイクルを採用する。この評価では、1日の発電エネルギー量は正確に予測できるものと仮定した。これは実際にはあり得ないが、比較相手としてこの理想的な状況を想定した。図4に、2010年の東京地点のデータを利用して評価を行った結果を示す。

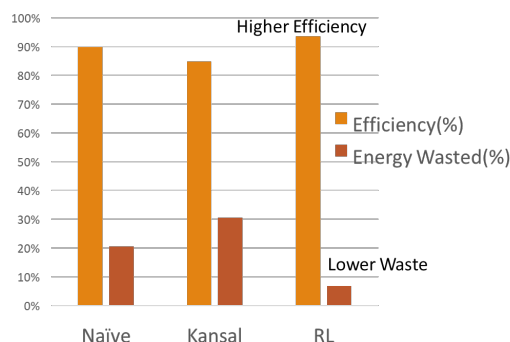


図4：提案手法と従来手法の比較結果

評価指標としては、理想的に達成可能な平均デューティサイクルに対して、実際に選択されたデューティサイクルの比率(Efficiency)と、年間を通した全発電エネルギー量に対してバッテリーが満充電となり収集できたにもかかわらず使われなかったエネルギー量(Energy Wasted)を用いた。図4より、提案手法であるRL(Reinforcement Learning)が他の従来手法よりも両評価指標において優れていることがわかる。

環境発電に頼る場合、発電エネルギー量は、

センサーノードが設置された場所により大きく異なる。広域分散センシングシステムにおいては、学習時と異なる場所に設置された場合にも、発電エネルギー量の違いに適切に対応できることは重要である。そこで、東京での2000年から2009年の日射量データにより学習を行った後に、気候条件が異なる稚内に移設した場合の評価を行った。その結果を図5に示す。




図5：設置場所を移設した場合の平均デューティサイクルとバッテリー切れの回数

この図では、移設後の各年の平均デューティサイクルを示している。また、括弧内の数字は、当該年にバッテリー切れが発生した回数を示している。図ではGreedy法とε-greedy法の2つの結果を示した。

図からわかるように、2011年から2013年にかけて、Greedy法ではバッテリー切れが数回発生しているにも関わらず、ε-greedy法によりオンラインで学習を行うことでそれが回避されている。このことから、学習場所と設置場所が異なる場合にもオンライン学習を行う提案手法が適切に対応できていることがわかる。一方で、Greedy法に比べてε-greedy法では若干平均デューティサイクルが減少している。これは探索時に最適とは限らない行動をランダムに選択するためであると考えられる。

これらの結果から、提案する強化学習を用いた環境発電駆動センサーノードのデューティサイクル管理手法は、人手によるチューニングを必要とせず環境からの状態のみを入力としているにも関わらず、ENO-Max条件が達成されていることがわかり、設置場所の違いにも適応可能であり空間的適応性を有することもわかった。これらの結果より、提案手法は様々な場所に膨大な数のセンサーが設置されるIoT時代の環境発電駆動センサーノードの電力管理手法として有用なものになると結論付けることができた。

5. 主な発表論文等

(研究代表者、研究分担者及び連携研究者には下線)

[雑誌論文](計2件)

T. Nakada, T. Hatanaka, H. Ueki, M. Hayashikoshi, T. Shimizu, H. Nakamura,

An Energy-Efficient Task Scheduling for Near-realtime Systems with Execution Time Variation, IEICE Trans. on Information and Systems, (Reviewed) Vol.E100-D, No.10, pp.2493-2504, Oct. 2017, DOI:10.1587/transinf.2016EDP7497
S. Shaswot, M. Kondo, H. Nakamura, Adaptive Power Management in Solar Energy Harvesting Sensor Node Using Reinforcement Learning, ACM Trans. on Embedded Computing Systems (TECS),(Reviewed) Vol. 16, Issue 5s, Article No. 181, Oct. 2017, DOI: 10.1145/3126495

[学会発表](計6件)

T. Nakada, H. Yanagihashi, K. Imai, H. Ueki, T. Tsuchiya, M. Hayashikoshi, H. Nakamura, Energy-aware Task Scheduling for Near Real-time Periodic Tasks on Heterogeneous Multicore Processors, IFIP/IEEE International Conference on Very Large Scale Integration (VLSI-SoC), 6 pages, Oct. (2017)

S. Shaswot, M. Kondo, H. Nakamura, Reinforcement Learning for Power Management in Energy Harvesting Sensor Nodes, Poster Presentation, ACM/IEEE Design Automation Conference, June 2017
 シュレストマリ サソット, 近藤 正章, 中村 宏, 適応的電力制御を行う環境発電駆動センサーノードの強化学習戦略の比較評価, 情報処理学会研究報告 2017-ARC-227, No.28, pp.1-8, (2017)

シュレストマリ サソット, 近藤 正章, 中村 宏, 強化学習を用いた環境発電駆動センサーノードの適応的電力制御手法の検討, 情報処理学会研究報告 2017-ARC-225, No.26, pp.1-6, (2017)

T. Nakada, H. Nakamura, T. Nakamoto, T. Shimizu, Normally-off power management for sensor nodes of global navigation satellite system. ISOC 2016: 193-194

T. Nakada, T. Hatanaka, H. Ueki, M. Hayashikoshi, T. Shimizu, H. Nakamura, An Adaptive Energy-Efficient Task Scheduling under Execution Time Variation based on Statistical Analysis, IFIP/IEEE International Conference on Very Large Scale Integration (VLSI-SoC) (poster), 7pages Sep. (2016)

[図書](計0件)

[産業財産権]

出願状況(計0件)

取得状況(計0件)

[その他]なし

6. 研究組織

(1) 研究代表者

中村 宏 (NAKAMURA Hiroshi)
東京大学・大学院情報理工学系研究科・教授
研究者番号：20212102

(2) 研究分担者：なし

(3) 連携研究者

中田 尚 (NAKADA Takashi)
奈良先端科学技術大学院大学・先端科学技術
研究科・准教授
研究者番号：00452524

(4) 研究協力者：なし