

部品エージェントのためのライフサイクルシミュレーションへのベイズ推定の利用 Bayesian Estimation for Life Cycle Simulation of Parts with Part Agent

精密工学専攻 44号 福永 義規
Fukunaga Yoshinori

1. 序論

近年, 大量生産, 大量消費型社会から循環型社会へと変化が急務となっている⁽¹⁾. 循環型社会にしていくためには, リユース技術の向上や, 消費者のニーズを満たしながら再利用部品を効率的に使用していくことが必要である. そのために, 個々の部品に付ける部品エージェントによって, ライフサイクル中の部品を管理する部品エージェントシステムの開発を行っている⁽⁴⁾.

消費者が再利用製品の利用を考える際には, 消費者の特性を踏まえた上で判断できる環境が求められる. また, 現状の製品よりも, 交換したときに部品の性能が向上することが分かれば, 消費者のニーズを満たしつつ部品のリユース促進に繋がると考えられる. 先行研究⁽²⁾では, 部品エージェントが, 部品のライフサイクルにしたがってライフサイクルシミュレーションを行い, その結果を利用し, ユーザに保全行動を提案する機能の開発が行われてきた.

今回, ライフサイクルシミュレーションの精度を向上させるために, 機械部品の劣化に着目した. 機械部品の劣化は, 温度などの使用環境や使用頻度や使用強度などの使用状況に応じて変化する. しかし, 故障の発生とその要因との定量的関係は, 確率的性質のために明確に決定することができない. この問題を扱うために, ベイズ推定⁽⁵⁾を用いる. ベイズ推定は, 事象間の不確実な事象の確率を推論できるので, ユーザの行動によって生じる事象の確率に基づいて, 製品の故障の発生確率を推定するために使用できる. ベイズ推定を使用して, ライフサイクルからユーザに適切な動作を提案することが可能であると考えている.

そこで本研究では, 機械部品の劣化に関する因果関係ネットワークを作成し, ライフサイクルシミュレーションにこれを組み込み, 以前より精度の高いシミュレーションを実現することを目的とする.

2. 部品エージェントシステム

部品エージェントシステム⁽³⁾とは, 部品エージェントが, ライフサイクル全体にわたって対応する部品に関するすべてのデータを管理するシステムである. このシステムは, ネットワークと高精度 RFID 技術の普及を前提としている.

部品エージェントは, コア部品の製造段階で RFID タグが対応する部品に取り付けられると生成される. 部品エージェントは, 部品のライフサイクル中に RFID タグの ID を識別し, ネットワークを介して部品を追跡する. RFID を採用する理由は, 印刷されたバーコードよりも汚れや変色に対する抵抗があり, 長期間のライフサイクルにわたって使えるためである.

Fig. 1 に部品エージェントシステムの概念図を示す. 部品エージェントは, ネットワーク内の様々な機能と通信し, 製品設計情報, 部品の予測劣化情報, ロジスティック情報, マーケット情報など対応する部品の管理に必要なデータを収集する. また, 部品の状態を検出するセンサー機能, 個々の部品データの記憶機能, 製品の管理機能, および制御機能などの現場機能と通信する. 通信は, 部品エージェントによって生成された従属ネットワークエージェントである情報エージェントを使用して確立される.

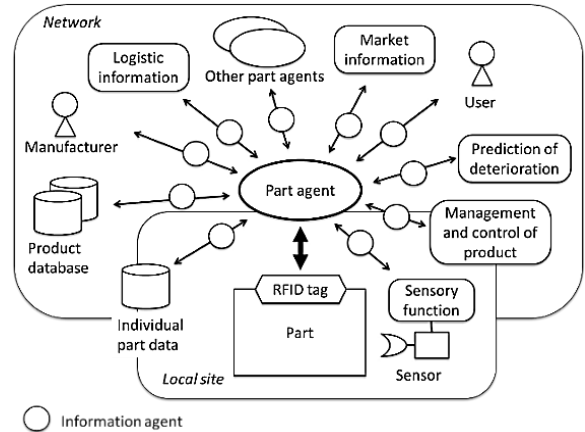


Fig. 1 Conceptual scheme of part agent

3. ライフサイクルシミュレーション

部品エージェントは, 部品のリユースに対する適切なアドバイスを生成するために, 対応する部品の将来の状態を予測する機能を必要とする. このために部品エージェントは, 取得された情報に基づいて部品のライフサイクルシミュレーションを実行する.

Fig. 2 は, 一例として単純なライフサイクルモデルを示している. 生産, 販売, 使用, 修理, 廃棄のようなライフサイクル中の段階をライフサイクルステージといい, ライフサイクルステージを繋ぐ経路をライフサイクルパスという⁽²⁾. 図では丸でライフサイクルステージを, 矢印でライフサイクルパスを表す. ライフサイクルモデルは, ライフサイクルステージとライフサイクルパスから構成する.




Fig. 2 A simple life cycle model

部品エージェントは, 部品のライフサイクルを展開ライフサイクルモデルに変換する. これは, 時間の経過とともに部品のライフサイクルに起こりうる変化を表している. Fig. 3 は, 「Use」ステージから展開された部品のライフサイクルの例を示す. 展開ライフサイクルでは, ステージは, 部品の利益, コストおよび環境負荷を有し, ライフサイクルパスは部品がそのパスを通る確率を有する.

このように展開されたライフサイクルの情報に基づいて, 部品エージェントは, 現在のライフサイクルステージから開始する候補ステージの期待値を計算する. 期待値は, ステージの値の積和と候補ステージから分岐するパスの確率を累積することによって得られる.




Fig. 3 Expanded life cycle model

ルート毎の期待値をEVとするとEVは式(1)のように計算される. この時, Vは各ステージの値, Pはそのステージにつながるパスの確率である.

$$EV = \sum_{Route} \left(\sum_{Stage \text{ in route}} V * \prod_{Path \text{ in route}} P \right) \quad (1)$$

これを用いると, Fig. 4の例に示すように, Stage1の期待値は式(2)のように求められる.

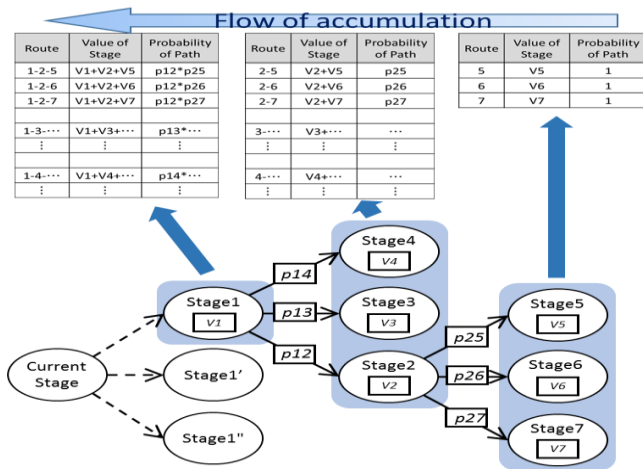


Fig. 4 Process of accumulating the values of life cycle

$$\begin{aligned} \text{expected value(Stage1)} = & (V1 + V2 + V5) * (p12 * p25) + (V1 + V2 + V6) \\ & * (p12 * p26) \\ & + (V1 + V2 + V7) * (p12 * p27) + (V1 + V3 + \dots) * (p13 * \dots) \quad (2) \\ & + \dots \end{aligned}$$

ライフサイクルステージのコストや利益などの値は, ステージ内の部品の状態に基づいて見積もることができる. しかし, ライフサイクルパスの確率を推定することは困難である. この問題に対処するために次の章で, 不確実な事象を推定できるベイズ推定とベイジアンネットワークの適用について議論する.

4. ベイズ推定による保全行動の選択

4.1 実験の背景

部品の使用条件と故障及び不具合の可能性との関係は, 簡単には判断できない場合が多い. 例えば, ハードディスク装置 (HDD) の故障については, Google 社の調査⁽³⁾によって使用条件 (温度) と故障の関係性がある程度示されているものの, あくまで確率的な統計であり, 使用条件と故障の因果関係には不透明な部分が多い. また, HDD の種類によっても劣化に差が見られる.

このように不確実性の高い劣化と不具合の発生について, 製造段階での評価に限界があるとしても, 部品エージェントがライフサイクル全体において情報を取得し続けることに

よって, 関連するデータを随時追加し, 徐々に評価の精度を高めていくことができるものとする. 本研究では, 不確実性を含む確率の推論を行うベイジアンネットワークを用いて, 消費者の特性と部品の状態の因果関係を表現し, 確率を推定することによって評価を行う.

今回は, HDD の劣化情報をもとにベイジアンネットワークを作成する. なお, ベイジアンネットワークの基本的な概念については, 付録 A に記載する.

4.2 HDD モデル

ベイジアンネットワークを使用して, 消費者の特徴と部品の状態の関係性を評価するため, HDD の劣化に関する因果関係モデルを作成した. Fig. 5 が作成した HDD の劣化に関する因果関係を表すベイジアンネットワークである. 図中の A から G までのイベントは, 悪い環境での使用, 高温状態での使用, 振動, リユース, 廃棄, 異音の発生および部分的な不良セクタの発生を示している. 入力イベントは A, B, C で, 観察できないイベントは D と E, 観測イベントは F と G である. 観測イベントは, センサなどで検出できるものとする.

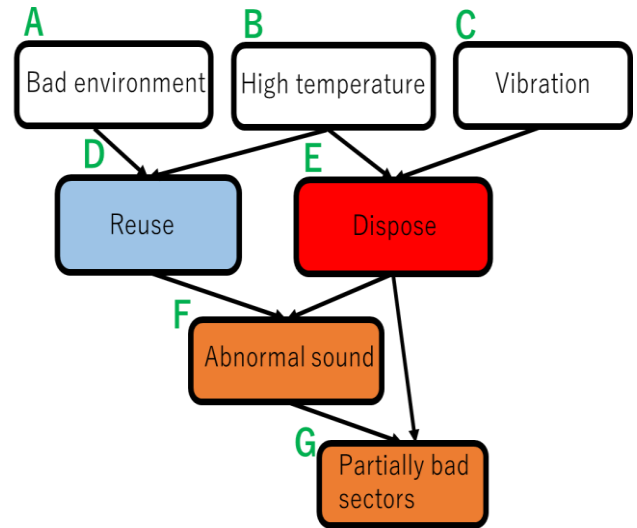


Fig. 5 Representation of deterioration relations

異音イベントが発生した場合, 検出できないリユースイベント (Reuse) と廃棄イベント (Dispose) の発生確率 P (D | F) および P (E | F) を計算する. 今回は, 8 人のユーザーで検証する. それらの事前確率を Table. 1 に示す. 条件付き確率を Fig. 6 に, 結果を Fig. 7 に示す.

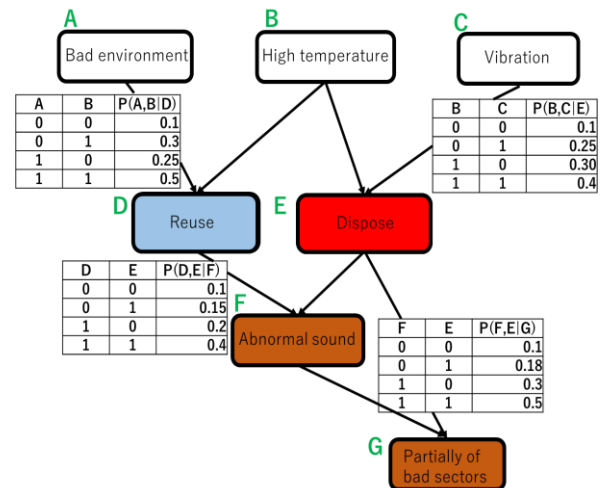


Fig.6 Conditional probability of deterioration

Table 1 Prior probability of users

	A. Bad environment	B. High temperature	C. Vibration
User1	0.1	0.1	0.1
User2	0.1	0.9	0.9
User3	0.1	0.9	0.1
User4	0.1	0.1	0.9
User5	0.9	0.1	0.1
User6	0.9	0.1	0.9
User7	0.9	0.9	0.1
User8	0.9	0.9	0.9

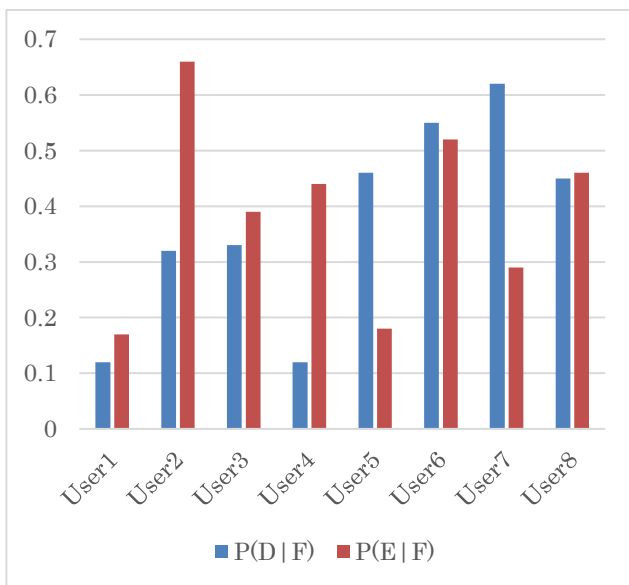


Fig. 7 Posterior probability of abnormal sound

Fig. 7 の結果から、異音が聞こえた場合、HDD 内で起きることは、ユーザによって異なることがわかった。観察不能イベントの Reuse が起きている可能性が高いのは、User1, 2, 3, 4, 8 で、観察不能イベントの Dispose が起きている可能性が高いのは、User5, 6, 7 である。したがって、ユーザごとに観察不能イベントの発生予測をすることができることがわかった。これは、HDD をリユースする際にユーザにとって有益である。

この結果から、消費者の特性によって変化する観察不能な事象の発生確率を予測することが可能であることが分かった。これにより、ライフサイクルシミュレーションにベイジアンネットワークを組み込み、精度を上げることができると考えた。次の章で、組み込み方法の提案をする。

5. ライフサイクルシミュレーションへのベイズ推定の利用

5.1 ベジアンネットワークの適用方法

3 章で説明したように、ライフサイクルシミュレーションにおける期待値を計算するためには、ライフサイクルパスの確率、すなわち展開されたライフサイクルにおけるライフサイクルステージ間の確率が必要である。これまで説明したベ

イジアンネットワークを、これらの確率を得るために適用する。

Fig. 8 に本研究で提案するライフサイクルシミュレーションにベイジアンネットワークを用いて、ライフサイクルパスの確率を計算する方法を示す。Fig. 8 の上段にある丸と矢印で構成されたものが展開ライフサイクルを示している。丸はライフサイクルステージを、矢印はライフサイクルパスを示す。丸の中にある四角はライフサイクルステージ内で起こる事象（以下イベントとする）を示す。各ライフサイクルステージで観測されたイベントを青色の四角で示す。イベントの発生を検出すると、ベイジアンネットワークを利用し、ベイズ推定が行われ、ライフサイクルステージからでるパスの確率、すなわち別のステージへの遷移につながるイベントの発生確率を推定できる。

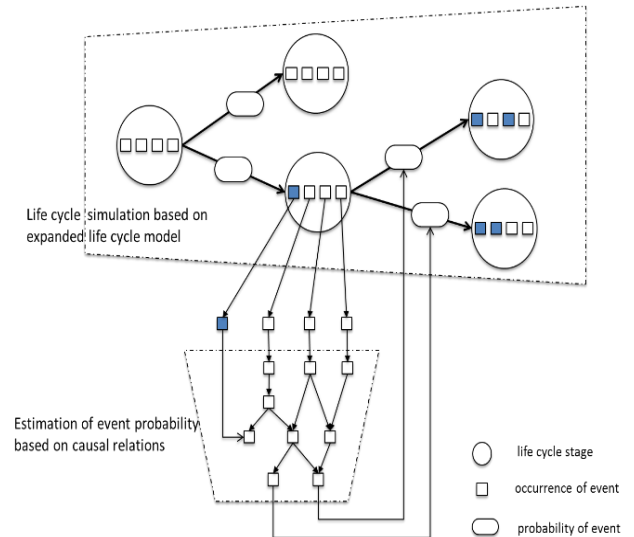


Fig. 8 Integrating expanded life cycle model with Bayesian estimation of events

5.2 例題でのシミュレーション

Fig. 9 のライフサイクルパスの確率 p_1 , p_2 を求めるためにベイジアンネットワークを利用する。ベイジアンネットワークでのイベント A, B, C は Table. 2 の値を、条件付確率は Fig. 6 のものを利用する。ライフサイクルシミュレーションのパスの確率 p_1 , p_2 は、ベイジアンネットワークで推定された Reuse イベントと Dispose イベントの確率の値をそれぞれ使用とする。Use ステージから Use ステージに行く場合は、1 から p_1 と p_2 の確率を引いた値とする。今回は 1 人のユーザで検証する。

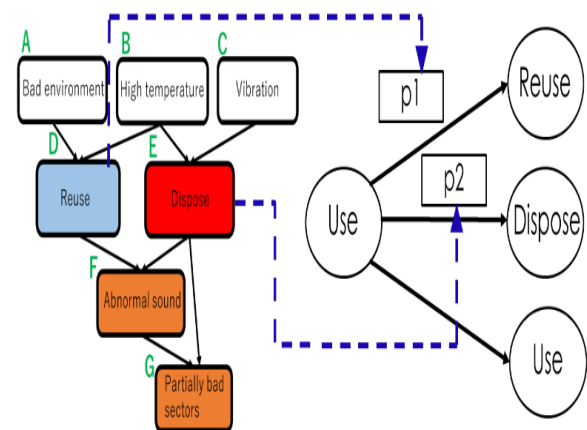


Fig. 9 Life cycle pass from Bayesian Network

Table.2 Prior probability

	A. Bad environment	B. High temperature	C. Vibration
User1	0.5	0.5	0.5

5.3 シミュレーション結果

5.2 のライフサイクルで、ベイジアンネットワークを使用した場合としない場合での期待値を求めて比較した。その結果を Fig. 10 に示す。

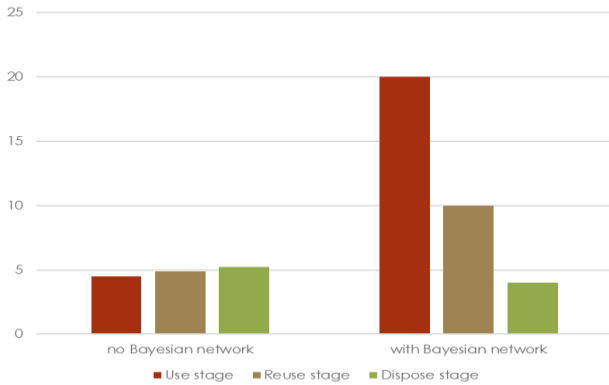


Fig.10 Comparison of expected value

Fig10 の左側がベイジアンネットワークを使用せずに固定確率でシミュレーションを行った場合で、右側がベイジアンネットワークを使用してシミュレーションを行った場合を示す。

三つの項目は Use ステージからの行き先を示しており、左から順に Use ステージ, Reuse ステージ, Dispose ステージとなっている。ベイジアンネットワークを使用しなかった時は、先行研究⁽²⁾と同様に、ライフサイクルパスの確率を一定にして使用しているため、選択するステージの期待値のばらつきがあまりみられなかった。逆に使用したときは選択するステージの期待値にばらつきを見ることができた。この結果により選択するステージを以前より正確に決めることができ、ライフサイクルシミュレーションの精度が上がったと考える。つまり、本手法は、リユース促進に効果があると考える。

この手法には解決しなければいけない課題がある。それは、どのようにしてベイジアンネットワークを作成するかということである。今回のシミュレーションでも同じ形、同じ条件付き確率を使用した。どの事象とどの事象が因果関係で結ばれるのか、その関係がどのような確率で起こるかなどを決めることは難しい。そこで、今後の課題は、既存のベイジアンネットワークを更新していき、より精度の高いベイジアンネットワークにしていく手法の開発と考える。そのような更新を実現するには、データの収集方法、更新する期間、新しい事象の組み込み方などが問題になると考えられる。これらの問題点を解決するために、事象などの情報を集めた包括的ベイジアンネットワークを作成することが一つの方法であると考える。

6. 結論

本研究では、HDD の劣化に関する因果関係を表すベイジアンネットワークをリユースの判断に使えることを示した。この結果を用いて、ライフサイクルシミュレーションのパス確率の計算にベイズ推定を適用する手法を開発した。

参考文献

- (1) 環境省_循環型社会形成推進基本法の趣旨, <http://www.env.go.jp/recycle/circul/kihonho/shushi.html>,(2017/6/10 accessed)
- (2) Y.Yokoki, K.Nanjyo, Y.Yamamori, H.Hiraoka, “User model in the life cycle simulation of mechanical parts”, *eco design*(2015), p353-365
- (3) 上野達郎, 加藤慧, 大川宏史, 南條佳祐, 平岡弘之, “ベイズ推定を用いた部品エージェントによる機械部品の再利用支援” *精密工学会誌*(2013), Vol. 79(12), p1258-1264.
- (4) H. Hiraoka, Ueno, K. Kato, H. Ookawa, M. Arita, K. Nanjo, H. Kawaharada, Part Agent Advice for Promoting Reuse of the Part Based on Life Cycle Information, 20th CIRP International Conference on Life Cycle Engineering (2013); p335-340.
- (5) Bayesian Network introduction <https://www.synergy-marketing.co.jp/blog/introduction-bayesian-network>, (2017/5/21 accessed)
- (6) 福永義規, 横木弓人, 平岡弘之, (2016) “部品エージェントによる機械部品の再利用のためのベイジアンネットワーク”, *精密工学会秋季大会学術講演会*(2016).

付録 A. ベイジアンネットワーク

事象 A が事象 B に影響を与えるとして、事象 A と事象 B との間の因果関係を考える。事象 A が発生する確率を事前確率と呼び、 $P(A)$ と表す。事象 A が発生した後に事象 B が発生する確率は条件付き確率と呼ばれ、 $P(B|A)$ と表す。 $P(B)$ はデータで習得することができる値である。事前確率 $P(A)$, データ $P(B)$, 条件付き確率 $P(B|A)$ がわかっているならば、 $P(A|B)$ を得ることができる。これは以下の式 (3) で表されるベイズ定理により計算できる⁽⁶⁾。

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

$P(A|B)$ は事後確率と呼ばれる。複数のイベントが存在する場合、イベント間をつなぐとネットワークを形成する。これをベイジアンネットワークと呼ぶ。各ノードには、条件付き確率表と呼ばれるものが付いている。

Fig. 11 は、ベイジアンネットワークの簡単な例を示す。左側に示すグラフは、イベント A と C がイベント B の発生に影響することを示している。条件付き確率 $P(B|A, C)$ は、イベント A, C の発生パターンにより確率が変わるので、Fig. 11 の右側に示す条件付き確率表にまとめられる。




Fig. 11 Example of Bayesian network with conditional probability table

ベイジアンネットワークでは、入力イベント、観測可能なイベント、および観測不能なイベントの 3 種類のイベントがある。イベントの条件付確率がある場合、上記のベイズ定理を使用してネットワーク内の観測不能イベントの発生確率を推定し、入力事象および観測事象が観測不能イベントに与えている影響の確率がわかる。