

需要の非定常変動環境下におけるベイジアンネットワークを用いた 解釈性のある安全在庫量の決定

Interpretable determination of safety stock using Bayesian networks in non-stationary environments

木本 翔太[†] 石垣 綾[†] 有水 大地[‡] 森山 健[‡] 井對 貴之[‡]

Shota Kimoto Aya Ishigaki Daichi Arimizu Takeru Moriyama Takayuki Itsuki

1. はじめに

企業の発注量を決める在庫管理において、製品の需要を予測することは利益最大化やコスト最小化のために重要である。しかし、将来の需要は未知であるため、需要予測量との差により、過剰在庫による在庫保管費の増加や、品切れによる機会損失を被るリスクがある。このようなリスクを軽減するために、企業はサプライチェーンリスクマネジメント (SCRM) に注目している。多くの従来研究は、予測誤差が独立同一分布に従うと仮定し、需要の不確実性のリスクに対処するために、需要予測に焦点が当てられてきた。しかし、需要が非定常な環境下ではこの予測誤差の不確実性の仮定は成り立たないことが多い。そのため、近年は予測誤差のリスクに焦点を当て、需要の非定常な環境下における安全在庫量決定方法が研究されている[1]。このように、企業は品切れや過剰在庫のリスクに対し様々なアプローチを利用することができる。

しかし在庫管理の現場では、様々な要因を総合的に判断し、需要予測量に調整として熟練した在庫管理者が安全在庫量を加えた発注を行っている現状がある。そのため、発注量決定プロセスが属人化しており、少子高齢化社会の進む日本では持続可能性の面から問題視されている[2]。この問題に対し、AIを用いた発注量決定方式が導入されている。しかし、在庫管理者はAIなどにより導かれた予測結果に懐疑的であることが多い。そのため、在庫管理者は自身の直感と比較し、そぐわない結果が得られた場合は高精度な予測結果であったとしても意思決定に使用することに消極的になるリスクがあることが指摘されている[3]。そのため、発注量決定において熟練者への属人化を解消するには、在庫管理者の直感に沿った安全在庫の決定方法を提案する必要がある。本研究では在庫管理者の直感に沿うということを、需要に影響を与える外部要因などの変数間の関係性がわかることと定義する。そこで、変数間の依存関係のモデリングが可能なベイジアンネットワークを用いて外部要因と需要の関係性を示しながら安全在庫量を計算し、意思決定プロセスの明示化を行う。これにより需要の非定常な環境下においても、熟練者でなくとも容易に在庫管理の意思決定を行える環境設計を行うことを目的とする。

2. 安全在庫量決定方法

在庫管理において、需要予測誤差に対処するためにSCRMが注目されている。需要予測の外れである予測誤差のリスクを軽減するために安全在庫量が設定される。需要予測の外れが平均 0、分散一定の独立同一分布に従う場合、

目標サイクルサービスレベル (CSL) に対する安全在庫は以下の式(1)で表される。

$$SS_1 = k\sigma_L \quad (1)$$

$k = \Phi^{-1}(CSL)$ は安全係数であり、 $\Phi(\cdot)$ は標準正規分布の累積分布関数である。 σ_L はあるリードタイム L の予測誤差の標準偏差である。これは一般に一定で既知であると仮定される。しかし、需要の非定常な環境下では、この過程は成り立たない。 σ_L は経時的に変化する可能性があり、式(1)による安全在庫量決定方法は σ_L をどのように推定するかが課題となる。これには、理論的アプローチと経験的アプローチの2つのアプローチがある。

2.1 理論的アプローチ

理論的アプローチでは、予測誤差が独立同一分布に従うと仮定し、1期後の予測誤差 σ_{t+1} を推定することで、リードタイム中の予測誤差 σ_L を推定する。

$$\sigma_{t+1} = \sqrt{\alpha(y_t - F_t)^2 + (1 - \alpha)\sigma_t^2} \quad (2)$$

式(2)は、単一指数平滑化法 (SES) を用い、 t 期の平均二乗誤差 (MSE) を σ_t としたときの σ_{t+1} を推定している[1]。式(2)を用いて推定された σ_{t+1} から、理論的アプローチは式(3)を用いて σ_L を推定する。

$$\sigma_L = \sqrt{L}\sigma_{t+1} \quad (3)$$

2.2 経験的アプローチ

前節で述べた理論的アプローチは、予測誤差が独立同一分布に従うと仮定している。しかし、式(3)には理論的正当性がなく、適していないことが指摘されている[1]。そのため、需要の真のモデルが未知の場合は経験的アプローチが用いられる。Trapero et al.[1]は、予測誤差が正規分布に従うと仮定できる場合、パラメトリックアプローチであるGARCHモデルを用い、仮定できない場合にノンパラメトリックアプローチであるカーネル密度推定により σ_L を推定した。これらの手法を用い、需要の非定常な環境下において企業のコスト削減に貢献した。

2.2.1 パラメトリックアプローチ

GARCH(p,q)モデルは、時間 t における予測誤差 ε_t の条件付き分散 σ_t^2 を、正規分布に従う仮定の下で p 個の過去の分散項、 q 個の過去の誤差項の線形関数として表現する手法である。GARCH(1,1)モデルは式(4)で表される。

$$\sigma_{L,t+1}^2 = \omega + \alpha\varepsilon_{L,t}^2 + \beta\sigma_{L,t}^2 \quad (4)$$

$\sigma_{L,t}^2$ は t 期におけるリードタイム L の分散であり、 $\varepsilon_{L,t}$ は t 期におけるリードタイム L の予測誤差である

2.2.2 ノンパラメトリックアプローチ

カーネル密度推定は、データの分布に関する仮定を必要とせず、リードタイム予測誤差の確率密度関数 $f(x)$ を表す。

[†] 東京理科大学 Tokyo University of Science

[‡] 三菱電機 Mitsubishi Electric Corp.

ある点 x における系列 X のカーネル密度関数は式(5)で表される。

$$f(x) = \frac{1}{Nh} \sum_{j=1}^N K\left(\frac{x - X_j}{h}\right) \quad (5)$$

ここで、 N はサンプル数、 $K(\cdot)$ はカーネル関数、 h は帯域幅である。カーネル密度推定は、ノンパラメトリックアプローチのため、予測誤差が正規分布に従うと仮定できない場合に有効な手法である。

3. 提案手法

前節のように、予測誤差の標準偏差 σ_L を安全在庫量決定に用いる手法は、予測誤差の従う分布に依存しており、多くは未知であることが問題である。一般に、需要には長期的な変動であるトレンド成分、短期的に繰り返す変動である周期性成分、残差成分が含まれている。このような変動を持つ時系列データに対し、様々な分解手法が提案されている。Loess を用いてこれらの成分に分解する STL 分解は、トレンド、周期性、残差の三つの変動に分解するロバストな手法である。残差は不確実性を含み、本来は予測不可能な部分である。従って、トレンド成分と周期性成分を予測可能な需要予測モデルを仮定すると、予測誤差は STL 分解による残差成分と等しくなる。STL 分解により分解された残差成分は平均 0、分散一定と仮定されている。本研究では、STL 分解を用いて需要予測を行い、その予測誤差を平均 0、分散一定を仮定できる STL 分解の残差であると仮定し、安全在庫量を決定する方式を提案する。

一方で、短期的に残差成分を見ると、トレンドや分散の変化などの特徴を持つことが指摘されている[4]。そのため、目標 CSL を保つためには、予測誤差のトレンドを考慮する必要がある。また、残差成分は予測不可能でランダムな変動を含むため、分散の推定を同時に行う必要がある。

一方でこのように、求められた結果に対して直観にそぐわない結果の場合、精度が高かったとしても意思決定への活用には消極的になるリスクが指摘されている[3]。また、自動車産業を例に挙げると、特有の製品開発サイクルの長さから、非線形かつ非定常な変化や多様なマクロ経済変数などの外部要因との依存関係が需要に影響を与えることが知られている[5]。そこで本研究では、ベイジアンネットワークを用い、需要に影響を与えるマクロ経済変数と過去の予測誤差を用いて予測誤差のトレンドと分散を解釈性高く推定し、安全在庫量を決定する。

3.1 フレームワーク

本研究で提案する安全在庫量決定方式は、以下の Step1 ~3 で構成される。

Step1 STL 分解

まず初めに、STL 分解[6]を行い、需要をトレンド、周期性、残差の 3 成分に分解する。トレンド、周期性成分を Step2 で需要予測に用い、予測誤差を残差成分と仮定し、Step3 で安全在庫量決定に用いる。

Step2 需要予測

本研究では、Trapero et al.[1]と同様に、企業に多く用いられている単純指数平滑化法 (SES) を用いてトレンドの予測を行う。周期性は、1 周期前の値をそのまま用いるナイーブ予測とする。これらの予測の和を需要予測量とし、予測誤差を残差成分と仮定する。

Step3 安全在庫量決定

ガウシアンベイジアンネットワークにより、マクロ経済変数と予測誤差から確率推論を行い、予測誤差の期待値 $\hat{\mu}_{L,t+1}$ と分散 $\hat{\sigma}_{L,t+1}$ を推定する。これを用いて以下の式(6)を用いて安全在庫量を決定する。

$$SS_2 = \hat{\mu}_{L,t+1} + k\hat{\sigma}_{L,t+1} \quad (6)$$

3.2 ベイジアンネットワーク

ベイジアンネットワークとは、因果関係を表すことができるモデルとして知られ、確率変数の集合の条件付独立性を表現するための有向非巡回グラフモデルである[6]。ベイジアンネットワークは離散値を扱うモデルであるが、各変数がガウス分布に従うと仮定することで連続値を扱うことができるのがガウシアンベイジアンネットワーク (Gaussian Bayesian Network; GBN) である。変数の集合を $X = \{X_1, \dots, X_n\}$ とし、変数 X の有向非巡回グラフ(DAG)を $G = (X, E)$ とする。ここで、 $(i, j) \in E$ を、 X_i から X_j への有向エッジが存在することと定義する。 $Pa_G(j) = \{i | (i, j) \in E\}$ を、 G における X_j の親ノードの集合とする。ガウシアンベイジアンネットワークは、各変数の条件付確率分布(Conditional Probability Distribution; CPD)は親ノードの線形結合として表されるガウス分布に従うとして、式(7)のように定義される[6]。

$$X_j | X_{Pa_G(j)} \sim \mathcal{N}\left(m_j + \sum_{i \in Pa_G(j)} w_{ij} X_i, \sigma_j^2\right) \quad (7)$$

ここで、 $X_S := \{X_i\}_{i \in S}$ とする。 m_j と σ_j^2 はそれぞれ X_j の基準レベルと条件付分散である。基準レベルとは、親の変数がすべて 0 の場合の、 X_j の平均値であり、他の変数の影響を受けない X_j の基本値である。 w_{ij} とは、エッジ (i, j) の因果の重みを表す。簡単のために、特定のグラフ G に対するパラメータ $\{m_j\}$ 、 $\{w_{ij}\}$ 、 $\{\sigma_j^2\}$ を θ^G と表記する。GBN モデル $M = (G, \theta^G)$ はガウシアン確率密度関数の積である X における結合確率密度関数を定義し、この結合確率密度関数が満たす独立性の仮定の集合はグラフ G によって表現される。また、モデル M に定義される結合確率密度関数は多変量正規分布となる。

このように定義されるベイジアンネットワークには、グラフ G を推定する構造学習、パラメータ θ^G を推定するパラメータ推定、観測データから事後分布を推定する確率推論の 3 つの機能がある。

3.2.1 構造学習

構造学習には、様々な手法が用いられている。一般には、得られたグラフがどの程度データを説明できているかを評価するスコアを定義し、DAG の解空間を探索する。しかし、企業の取得可能なマクロ経済変数は多くあり、変数の適切な選択が構造学習の精度に影響することが知られている。そのため、安全在庫量決定に用いるマクロ経済変数を適切に選択し、DAG を推定することは難しい。本研究では Arimizu et al.[7]の変数選択手法を用いて DAG を決定し、構造学習は行わない。

3.2.2 パラメータ推定

Arimizu et al.[7]の変数選択手法により設定したグラフ G と観測されたデータを用い、パラメータ θ^G の推定を行う。主な手法として最尤推定法やベイズ推定が一般に知られているが、本研究ではベイズ推定を採用した。アルゴリズムには EM アルゴリズムを用いている。

3.2.3 確率推論

グラフ G とパラメータ θ^G 、観測されたデータを用いて予測したい変数の確率推論を行うことができる。確率推論により、期待値 $\hat{\mu}_{L,t+1}$ 、標準偏差 $\hat{\sigma}_{L,t+1}$ は式(8)、(9)のように求められる。

$$\hat{\mu}_{L,t+1} = E[X_j | x_{Pa_G(j)}] = m_j + \sum_{i \in Pa_G(j)} w_{ij} x_i \quad (8)$$

$$\hat{\sigma}_{L,t+1} = V[X_j | x_{Pa_G(j)}] = \sigma_j^2 \quad (9)$$

確率推論には変分推論やマルコフ連鎖モンテカルロ法など様々なアルゴリズムが用いられているが、本研究では比較的計算量が少なく、想定されるマクロ経済変数の複雑な関係の処理に適しているジャンクションツリーアルゴリズムを採用している。

4. 数値実験

本研究では、提案手法の安全在庫量決定方式の評価を行うために、二つの実験を行う。一つは、データをランダムに生成し、状況を仮定したシミュレーションを行い、数値実験を行う。次章では実際のデータに適用し、ケーススタディを行う。

本章では、独立同一分布に従うマクロ経済変数を仮定し、Trapero et al.[1]と同様の環境で需要の標準偏差が変化する過程を生成する。ベンチマークの提案された環境における本研究の提案手法とベンチマークの比較により、考察を行う。

4.1 使用データ

独立同一分布に従うマクロ経済変数を仮定し、生成したデータの条件は以下である。

- i. 3つのマクロ経済変数 $V_{macro} = \{M_1, M_2, M_3\}$ を観測可能とする。
- ii. 1つの観測対象でない隠れ変数 V_{hidden} を用いる。
- iii. 需要 V_d は式(10)で表される V_{macro} と V_{hidden} との線形結合で表される。
- iv. V_{macro} は、正規分布、対数正規分布、ガンマ分布に従うと仮定し、3つの実験を行う。
- v. V_{hidden} は正規分布に従う。
- vi. V_{macro} 、 V_{hidden} はそれぞれ平均 150、20 である。
- vii. M_2 、 M_3 、 V_{hidden} の標準偏差はそれぞれ 25、25、10 である。
- viii. Trapero et al.[1]で仮定された需要の非定常性、標準偏差の変化を M_1 で表す。 M_1 は標準偏差が時期により変化すると仮定する。需要予測方式の学習期間、安全在庫量決定方式の学習期間、テスト期間でそれぞれ前半は標準偏差が 25 であり、後半は 50 となる。

$$V_d = \sum_{K \in V_{macro}} K + V_{hidden} \quad (10)$$

これらの条件でデータを生成し、シミュレーションを行った。ベンチマークには、SES、GARCH-X モデル、カーネル密度推定のそれぞれによる分散推定を用いた安全在庫量方式とする。GARCH-X モデルは、GARCH モデルに共変量を考慮したモデルであり、外部要因を用いて分散推定を行うことが可能である[8]。




図 1 数値実験に用いた DAG

なお、ガウシアンベイジアンネットワークにおいて、DAG を設定する必要があるため、図 1 のように設定した。

V_d は時系列データであるため、DAG に $t-1$ 期の予測誤差 $E_{d,t-1}$ が t 期の予測誤差 $E_{d,t}$ に影響を及ぼす仮定を置き、時系列のモデリングを行った。

4.2 実験結果

シミュレーションを 100 回行った結果を表 1 に示す。表 1 は、最も品切許容率に近い品切率であった手法を太字で示している。また、品切に対し、どの程度の品切個数が発生したかを平均品切数として評価し、最も値が小さい手法を太字で示している。結果から、BN を用いた提案手法は、マクロ経済変数の標準偏差の変化により需要の標準偏差が変化するという環境下では、ベンチマーク手法と同程度のパフォーマンスを示すことが分かった。本章のシミュレーション環境下では、品切率を評価指標とした場合、カーネル密度推定とベイジアンネットワークが最も良い手法であるといえる。これは、同一の標準偏差の変化が繰り返し現れる環境のため、過去のデータから安全在庫量を常に一定に保つカーネル密度推定に適している環境であったと考察される。一方で、安全在庫量をデータ駆動的に求める手法である SES、GARCH-X、提案手法である BN で比較すると、品切率では BN が最も優れていた。SES と BN を比較すると、SES は単一の時系列データをモデリングする手法であり、BN はマクロ経済変数のモデリングが可能のため優れた結果になったと考察できる。一方で、GARCH-X は条件付分散と、マクロ経済変数の線形結合で分散を推定する。そのため不確実性の考慮が難しく、不確実性をモデリング可能な BN が優れた結果になったと考察できる。

表 1 各分布・手法における品切率と平均品切数

正規分布	品切率[%]				平均品切数[個]			
	15	10	5	1	15	10	5	1
品切許容率[%]	15	10	5	1	15	10	5	1
BN	3.4	2.0	2.0	0.7	4.8	5.5	2.8	1.0
SES	25.7	17.6	7.4	3.4	4.9	4.1	4.7	1.6
GARCH-X	6.8	4.7	0.7	0.0	4.8	2.4	2.3	-
Kernel	12.2	6.8	2.0	0.0	4.9	3.8	4.9	-
対数正規分布	品切率[%]				平均品切数[×10 個]			
	BN	12.8	7.4	3.4	2.0	9.8	11.9	15.7
SES	22.3	20.3	16.9	13.5	18.6	18.0	17.4	14.7
GARCH-X	19.6	16.2	13.5	9.5	17.8	17.1	15.0	10.3
Kernel	13.5	10.1	2.0	0.0	14.4	11.2	12.1	-
ガンマ分布	品切率[%]				平均品切数[×10 ³ 個]			
	BN	10.8	10.1	8.1	6.1	2.1	2.0	2.2
SES	20.3	18.9	10.8	6.8	1.5	1.5	1.9	2.2
GARCH-X	18.2	16.9	12.8	10.8	1.5	1.6	1.9	2.0
Kernel	12.2	9.5	5.4	1.4	2.0	1.9	2.3	2.9




図 2 ケーススタディに用いた DAG

5. ケーススタディ

5.1 使用データ

需要データとして、一般社団法人日本自動車工業会から公表されているトヨタ自動車株式会社のブランドである LEXUS の売り上げデータ V_a を使用した。親ノードとして使用するデータは、企業が取得可能なマクロ経済変数データから Arimizu et al.[7] のフレームワークを用いて需要と関係のあるデータのみ絞りこんだ結果、需要に影響を与える変数として経済産業省から公表されている原油のヨーロッパからの輸入量 V_{oil} と、日本鉄鋼連盟から公表されている鉄の二次製品に関する輸入量 V_{steel} の二つの経済指標が選ばれた。これらのデータを用いて、図 2 の DAG が構築された。

5.2 実験結果

ケーススタディの結果を図 3、表 2 に示す。表 2 から、実際のデータにおける安全在庫量方式として、提案手法が最も優れていることが示された。品切率は提案手法が設定した品切許容率に最も近い手法であった。さらに、品切を起こした場合も、平均品切数が最も少ないことから、大きく外していないことが考察できる。

また、図 3 から、品切許容率によって大きく安全在庫量が増加していないことが読み取れる。これより、在庫管理において提案手法は、在庫水準を適切に保ちながら過剰在庫を抑え、在庫保管費の削減に貢献することができる手法だといえる。

6. おわりに

本研究では、需要の非定常な環境下においても、熟練者でなくとも容易に在庫管理の意思決定を行える環境設計を行うことを目的とし、ベイジアンネットワークを用いた需要の非定常性に対応可能な安全在庫量決定方式を提案した。

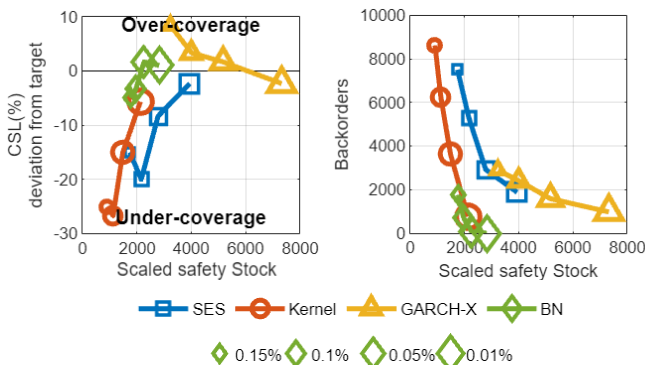


図 3 安全在庫量と CSL, 品切の比較

表 2 各手法における品切率と平均品切数

ケーススタディ	品切率[%]				平均品切数[個]			
	15	10	5	1	15	10	5	1
BN	19.4	12.9	3.2	0.0	2.9	1.8	0.7	-
SES	29.0	29.0	12.9	3.2	8.3	5.9	7.3	18.7
GARCH-X	6.5	6.5	3.2	3.2	14.5	12.0	15.8	9.7
Kernel	38.7	35.5	19.4	6.5	7.2	5.7	6.0	3.8

提案手法は、外部要因であるマクロ経済変数を用いてデータ駆動的に安全在庫量を求めるため、他の手法と比べて目標サービスレベルに近い品切率になり、企業のコスト削減に貢献できることが示された。

本研究の今後の課題は 2 点ある。1 つ目は、基本的な GBN を利用したため、分散の推定量が一定になっている点である。本来、様々な外部要因により残差成分の分散は変化する可能性があり、外部要因に応じて、分散推定を行うべきである。2 つ目は、解釈性としては変数間の関係性の明示に留まっており、解釈した結果から意思決定を支援できる方式に拡張することである。

参考文献

- [1] J. R. Trapero, M. Cardós, and N. Kourentzes, "Empirical safety stock estimation based on kernel and GARCH models," *Omega*, vol. 84, pp. 199–211, Apr. 2019, doi: 10.1016/j.omega.2018.05.004.
- [2] K. Dychtwald, T. Erickson, and B. Morison, "It's Time to Retire Retirement," *Public Policy Aging Rep.*, vol. 14, no. 3, pp. 1–28, Jun. 2004, doi: 10.1093/ppar/14.3.1a.
- [3] K. Coussement and D. F. Benoit, "Interpretable data science for decision making," *Decis. Support Syst.*, vol. 150, p. 113664, Nov. 2021, doi: 10.1016/j.dss.2021.113664.
- [4] D. Qu, K. Chen, S. Wang, and Q. Wang, "A Two-Stage Decomposition-Reinforcement Learning Optimal Combined Short-Time Traffic Flow Prediction Model Considering Multiple Factors," *Appl. Sci.*, vol. 12, no. 16, Art. no. 16, Jan. 2022, doi: 10.3390/app12167978.
- [5] A. Sa-ngasoongsong, S. T. S. Bukkapatnam, J. Kim, P. S. Iyer, and R. P. Suresh, "Multi-step sales forecasting in automotive industry based on structural relationship identification," *Int. J. Prod. Econ.*, vol. 140, no. 2, pp. 875–887, Dec. 2012, doi: 10.1016/j.ijpe.2012.07.009.
- [6] S. Sun, C. Zhang, and G. Yu, "A bayesian network approach to traffic flow forecasting," *IEEE Trans. Intell. Transp. Syst.*, vol. 7, no. 1, pp. 124–132, Mar. 2006, doi: 10.1109/TITS.2006.869623.
- [7] D. Arimizu, T. Nakamura, T. Ueda, A. Ishigaki, and H. Shibayama, "Explainable demand forecasting method using correspondence between economic indicator," *Proceeding 23rd Asia Pac. Ind. Eng. Manag. Syst.*, pp. 125–127, Oct. 2023.
- [8] H. Heejoon, "Asymptotic Properties of GARCH-X Processes," *J. Financ. Econom.*, vol. 13, no. 1, pp. 188–221, 2015, doi: https://doi.org/10.1093/jjfinet.023.