

在庫水準を専門家と同じように診断する AI モデルの改良

Improvement of AI Model That Makes the Same Evaluation of Inventory Level as Human Experts

在庫の管理は製造業の重要な業務の一つであり在庫の状況を診断し、問題が発生しそうな場合には早期に手を打つことが必要である。在庫状態は、在庫回転率、在庫日数、欠品率、即納率、バックオーダー解消日数などの様々な指標を組み合わせることで診断する必要がある。経験と知識の両方が必要とされる。そこで、誰でも熟練した在庫管理専門家と同じように在庫水準の診断ができる AI モデルを用いた在庫診断技術が研究されている。この AI モデルをある製造業者の在庫管理で実証を行ったところ、約 80% の精度で人間と同じ評価が可能であった。しかし別の製造業者に適用したところ、その精度は 60% まで低下した。そこで、両社で扱う製品の需要特性の違いに着目し、評価精度の改善を行った。AI モデルに入力するデータのスケール変換の見直し、0 値の扱いの見直しという二つの改善案を考案した。この改善を取り入れた AI モデルの精度評価を行ったところ、診断精度が 60% から 80% まで改善できることを確認した。

塚原 朋哉 Tsukahara Tomoya
清藤 駿成 Seito Takanari

1. はじめに

供給能力と需要のアンマッチを吸収するためのバッファである在庫の管理は製造業の重要な業務の一つである。適正な在庫水準とすることで、市場の変化への対応や資金の回転率向上などが実現できる¹⁾。

欠品を避けるためには在庫を多く持つと良いが、過剰在庫の可能性が高まり在庫回転率が低下する。逆に在庫回転率を上げ、過剰在庫を避けるには在庫を減らすと良いが欠品の可能性が高まる。このように在庫管理には欠品抑制と過剰在庫抑制という相反する目的がある。

一般に在庫を補充するには、発注をしてから納品されるまでに時間を要する。在庫が切れそうになってから発注しても間に合わない。逆に在庫が滞留し始めてから発注を止めても、その在庫が捌けるには時間がかかる。そこで、在庫の状況を診断し、問題が発生しそうな場合には早期に手を打つことが重要である。

在庫状態は、在庫回転率、在庫日数、欠品率、即納率、バックオーダー解消日数などの様々な指標を組み合わせることで診断する必要がある。経験と知識の両方が必要とされる。そこで、誰でも熟練した在庫管理専門家と同じように在庫水準の診断ができる AI モデルを用いた在庫診断技術が研究されている²⁾。

この AI モデルをある製造業者の在庫管理で実証を行ったところ、約 80% の精度で人間と同じ評価が可能であった。しかし別の製造業者に適用したところ、その精度は 60% まで低下した。そこで、両社で扱う製品の需要特性の違いに着目し、評価精度の改善を行った。

なお、本稿では、AI モデルが人間の専門家と同じように在庫の状態を評価できるかどうかを「精度」と呼ぶ。欠品率や在庫回転率などの在庫指標の評価は本稿では取り扱わない。




図 1 PSI データと教師データ例

2. 在庫水準を診断する AI モデル

在庫水準を診断する AI モデルは畳み込みニューラルネットワークで構成され、生産量 (Production)、販売量 (Sales)、在庫量 (Inventory) の時系列データ (PSI データ) を受け取り、人間の専門家と同じ診断結果を出力するように学習される²⁾。

入力の PSI データは 0 から 1 の間の値に線形にスケールを変換してから AI モデルに入力される。出力は「理想的」「普通」「欠品リスクあり」「欠品」「過剰」「超過剰」の 6 ラベルである。

学習に使われる教師データは期間で区切られた PSI データと、その PSI データの状態を表すラベルからなる。例を図 1 に示す。

図の縦軸が PSI データ (生産・販売・在庫) の数量、横軸が日付を表している。黄色い棒グラフが在庫を、オレンジの折れ線グラフが販売を、細い青い棒グラフが生産を表し、PSI グラフの背景色として教師データが表されている。教師データはその幅である期間と、その期間内の PSI データ診断結果であるラベルからなっている。ラベルは教師データの色として表現し、赤:欠品、ピンク:欠品リスク、水色:理想的、緑:普通、青:過剰、紫:超過剰を表す。

なお、前述のように人間の専門家が付けたラベルと同じラベルを出力するように学習が行われ、人間の専門家の診断との一致度合いを精度とする。実際のリスク量や欠品率、在庫回転率などの評価は本稿では取り扱わない。

3. AI モデルの改良

3.1 適用した製造業の特徴

在庫診断 AI モデルを A 社と B 社の 2 社に適用したところ、A 社では約 80% と高い精度で人間の専門家と同じ診断結果を出力したが、B 社では 60% 程度と精度が低かった。

そこで、両社の取り扱う製品の需要特性の違いに着目し改良を検討した。

A 社は消費財製造業であり、1 製品当たりの需要量が 1 日に数百以上と大量である。このため在庫量も多い。また製品 1 個あたりの単価も低い。消費者はその製品を購入する際、店頭が無ければ代替製品を購入することが多いなど欠品がすぐに機会損失となる。

B 社は修理用部品製造業であり、1 製品 (この場合は部品が製品である) 当たりの需要量は多くない。多くの製品は月に数個程度の需要である。このため、在庫量も数個という場合が多い。また、製品 1 個あたりの単価が高い場合が多い。修理用部品のためその場で在庫が無くてもある程度は待ってもらうことが可能である。ただし長期に待たせることは顧客満足度の低下や他社製品へのスイッチにつながるのでバックオーダー解消期間の短縮は重要な課題である。

3.2 需要特性の違いに着目した改良

A 社と B 社の取り扱う製品の需要特性の違いに着目し、AI モデルの改良を行った。本稿では特に「スケール変換の見直し」と「0 値の扱いの見直し」の 2 点の改良について述べる。

(1) スケール変換の見直し

2 章で述べたように PSI データは AI モデルに入力する前に 0 から 1 の間の数値に線形にスケール変換される。

スケール変換を行うと、A 社のように 1 製品当たりの需要量、在庫量が多い場合には、絶対値は違うけれども同じような需要や在庫の動きをする製品を同じように扱うことができ、学習効率が高まると考えられる。

しかし、B 社のように需要や在庫が少ない場合にはこのスケール変換が精度低下を引き起こしていると考えられた。例えば、在庫量が 2 個から 1 個に変化するのと 200 個から

100 個に変化するの、スケール変換をすると同じパターンになるが在庫管理の上では大きな違いがある。

また、B 社では 1 製品当たりの単価が高いので、在庫が一つ増えても在庫価格が大きく増えるため、個数の絶対値が重要な診断基準になる。

そこで、B 社への適用ではスケール変換を行わず PSI データの元の値をそのまま使用するように見直しを行った。

(2) 0 値の扱いの見直し

A 社では需要量や在庫量が多いため、これらの値が 0 になることは稀である。

しかし B 社では需要が月に数個程度しか発生しない製品が多くある。このような製品では日々の販売量はほぼ 0 である。また、在庫水準も低く抑えられ、また即納できなくても機会損失にならないことが多いため在庫量が 0 という状況もある。

今回用いた AI モデルでは、値が 0 の場合はモデルの計

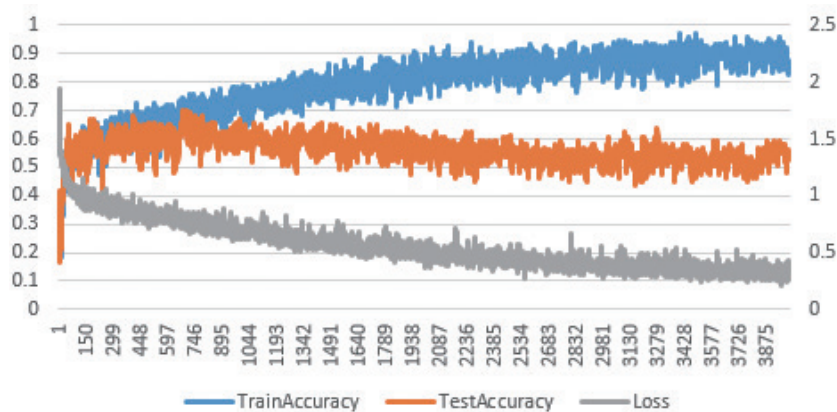
算に寄与しない。このため B 社の PSI データではモデルの学習が適切にできないと考えられた。そこで B 社への適用では値が 0 の場合は -1 に変換して AI モデルに入力するようにした。

予備実験で学習状況を確認したところ、値 0 を -1 に変換することでマイナスの値に強く反応する学習を行っていることが観察され、在庫がない、販売がない、という情報を診断に利用していることが確認された。

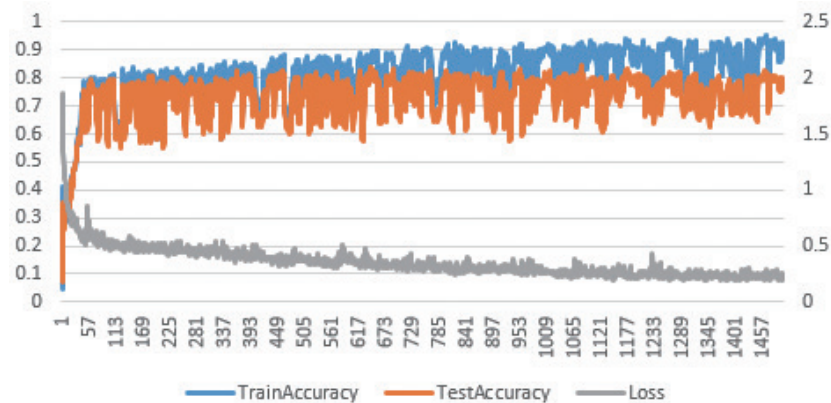
4. 診断精度改善の評価実験

(1) 実験データ

B 社の在庫管理を担当する熟練者が教師データを作成した。B 社の製品の実際の PSI データを熟練者が診断し、製品ごと期間ごとに「理想的」「普通」「欠品リスクあり」「欠品」「過剰」「超過剰」のどの状態にあるかのラベル付けを行う。



(A) 改良前 AI モデル



(B) 改良後 AI モデル

図 2 精度評価実験の結果（学習状況）

(2) 評価方法

ホールドアウト法により精度評価を行った。製品ごとの教師データから 1 データを抜き取り、それをテスト用のデータとする。テストデータ数は教師データ全体の 1 割程度である。残りの教師データで AI モデルの学習を行い、学習済み AI モデルの精度をテストデータで検証する。

これを改良前の AI モデルと、改良後の AI モデルで行い精度を比較する。精度は教師データ（すなわち人間の診断）との一致度合いである。

(3) 実験結果

図 2 に実験結果を示す。学習の進み具合を横軸に、訓練用データの診断精度を青で、テスト用データの診断精度を赤で表示し、モデルの収束具合を灰色（右側の軸）で表示する。

改良前の AI モデル（図 2 の A）ではテスト用データでの診断精度が 60%（0.6）程度であるのに対し、改良後の AI モデル（図 2 の B）では 80%（0.8）程度まで改善されていることが分かる。

5. おわりに

在庫診断を行う AI モデルを二つの製造業に適用したところ、A 社では 80% と高い診断精度であったが、もう一方の B 社では 60% と精度が低かった。両社で扱う製品の需要特性の違いに着目し、評価精度の改善を行った。

B 社は 1 製品当たりの需要量が少なく、また需要発生頻度も月に数回程度であり、在庫量も少ない。このため在庫診断には数値の絶対値が重要であり、スケール変換が診断に悪影響を与えていると考えられた。また、販売量、在庫量とも 0 となる日が多く、これらの値が AI モデルの計算に寄与していないと考えられた。そこで AI モデルに入力するデータのスケール変換の見直し、0 値の扱いの見直しという二つの改善案を考案した。

評価実験の結果、B 社での診断精度が 60% から 80% に改善できたことを確認した。


本稿では AI モデルが人間の専門家と同じ診断をすることを目的とした。専門家が間違った診断をしていれば AI モデルも間違った診断を行う。欠品率や在庫回転率などの従来から用いられている指標や、統計、リスク分析技術なども組み合わせて、専門家が間違った診断（教師データ作成）を行っても訂正できるような機能は今後の課題である。

また、現在の状態の診断が目的であるため、将来の状態

がどのようになるかを事前に診断することはできない。将来の予測診断も今後の課題である。

参考文献

- 1) 勝呂隆男, 適正在庫の考え方・求め方, 日刊工業新聞社, (2003)
- 2) 宗形 聡他, AI を用いた問題在庫の自動診断技術の研究, 日立ソリューションズ東日本技報 第 24 号 (2018)



塚原 朋哉 1997 年入社
研究開発部
機械学習・AI を用いた意思決定支援技術, 自然言語処理の研究開発



清藤 駿成 2017 年入社
研究開発部
機械学習・AI を用いた意思決定支援技術, 生産計画技術の研究開発