

AI を用いた問題在庫の自動診断技術の研究

Research on Item Inventory Level Diagnosis Based on a Convolutional Neural Network

多数の製品や部品を取り扱う企業では、欠品や過剰在庫を避けるために各品目の生産・販売・在庫を可視化し、問題在庫の検知や診断に利用している。在庫診断では、直近の在庫変動や販売傾向、生産量などの情報をもとに、在庫管理担当者が現状の問題の深刻度や要因、および対策方法を判断する。しかし、こうした判断は担当者の経験やノウハウに依存する部分であり、診断結果のばらつきが問題在庫の見逃しや解消の遅れといった課題につながっている。本報告では、現在研究している熟練担当者の在庫診断ノウハウを学習した AI モデルによる自動診断技術を紹介する。消費財メーカーの実データを用いて AI モデルの汎化性能を評価した結果、約 50% の診断精度が得られた。研究成果を実務で活用できるよう、今後は汎化性能の向上や診断根拠の説明を実現していく。

宗形 聡 Munakata Satoshi
清藤 駿成 Seito Takanari

1. はじめに

多数の製品や部品を取り扱う製造業や流通業では、需要と供給のバランスを取るために在庫を持ち、その数量を管理している¹⁾。需要に対して在庫が不足すると欠品となり販売機会を逃す一方、在庫が過剰になると余剰分の廃棄や乱売につながり、利益が減少する。

したがって、欠品や過剰にならない水準で在庫を管理することが企業の目標となるが、実際には、一人の担当者が管理する製品や部品の数は数百から数千になる場合も多く、販売計画と実需の乖離や生産効率を重視した製造部門による連続生産など日々生じる需給変動に対し常に適正な在庫を維持し続けるのは難しい。そのため、ときに過剰在庫や欠品などの問題在庫が発生してしまう。

(株)日立ソリューションズ東日本(以下、HSE と略す)では、膨大な製品や部品の PSI (Production: 生産, Sales: 販売, Inventory: 在庫) 可視化により問題在庫の早期検知を支援する技術の研究開発と製品化を進めてきた。これにより在庫管理担当者は、システムで問題在庫と検知された製品や部品に着目して、当該品目の PSI データの詳細や在庫評価指標を確認しながら、効率的な在庫診断を実施することができる。

在庫診断では、例えば「直近 3 ヶ月の販売が減少傾向であったにもかかわらず、生産ロットサイズが大きかったため在庫過剰になっており、在庫削減に向けた早急な減産調整が必要」のような、問題在庫の深刻度や要因、




図 1 PSI 可視化に基づく在庫診断の例

解決に向けた対策方法などが判断される。しかし、こうした判断は担当者の経験やノウハウによってばらつきが生じる部分である。多くの製品や部品を管理する企業では、在庫診断結果のばらつきにより問題の深刻度が過少あるいは過大に評価されたり、本質的要因以外の部分が要因と見なされたりすることによる問題在庫の見逃しや解消遅延といった需給調整業務の課題がある。

こうした状況の下、HSE では、熟練担当者による製品や部品の在庫診断履歴から、診断結果と関連する PSI の推移や相互の関係を特徴量として学習し、学習した特徴に基づき自動で問題在庫を診断する AI 技術の研究開発を進めている。本報告では、開発中の AI モデルの内容と現時点での診断精度の評価、および今後の課題と見通しについて述べる。




図 2 開発中の AI モデルのネットワーク構成

2. 問題在庫診断 AI モデル

担当者による製品や部品の在庫診断は、図 1 に示すように、時系列グラフとして可視化された日々の PSI の推移をもとに、必要に応じて在庫日数や安全在庫水準などの評価指標を参照して実施される。担当者は可視化された情報から診断対象となる期間の在庫変動や販売の増減傾向、生産量や生産間隔の関係を総合的に判断し、その中で診断結果につながる特徴を見出している。

近年では、画像認識やテキスト分類など様々な分類タスクに対して畳み込みニューラルネットワーク（以下、CNN と略す）が適用されるようになり、分類精度の著しい向上が実現した^{2,3)}。CNN では、フィルタと呼ばれる特徴検出器を持つ畳み込み層や、情報圧縮でノイズを除去するプーリング層を通して、ネットワークの学習と入力データの特徴抽出を同時に実現することができる⁴⁾。この特長により、AI はタスクに応じた適切な特徴量をデータ自体から自動で抽出できるようになり、人が事前に設計した特徴量を用いる従来の機械学習モデルよりも高い汎化性能を獲得することが可能となった。

在庫診断は、製品や部品の PSI データが与えられたときに在庫問題の深刻度を分類するタスクと見なすことができる。そのため本研究では、在庫診断時に担当者の判断の要点となっている生産、販売、在庫の状況や相互の関係を PSI データ自体から AI が学習し、問題の深刻度を高い精度で分類できるよう、CNN をベースとした AI 技術を開発している。

開発中の AI モデルのネットワーク構成を図 2 に示す。AI モデルは、大別して在庫診断と関連する PSI データの特徴を検出する特徴検出器と、検出した特徴量に基づき問題の深刻度を分類する分類器の 2 つから構成される。

モデルの入力は診断対象となる品目の PSI 時系列データ x である。入力をもとに 1 次元配列が PSI の 3 チャンネル分あるものとしてネットワークの入力層を構成する。

次の畳み込み層（Conv）では、一定期間の幅を持つフィルタを指定の間隔で時間方向に移動させながら畳み込み演算を実行する。PSI 時系列データ x の長さを T とするとき、時間 t を起点として期間幅 D のフィルタをストライド s で畳み込む演算は、次式のように書ける。

$$z_{0t}^k = \sum_c \sum_{d=0}^{D-1} w_d^{k,c} x_{st+d}^c + b^k \quad \left(t = 0, \dots, \frac{T-D}{s} \right).$$

ここで、 x^c は c 番目のチャンネルに対応する時系列データを表す。なお、下付きの添え字は配列のインデックスである。 $w^{k,c}$ はチャンネル c の k 番目のフィルタとなるパラメータである。 $w^{k,c}$ と x^c の内積を通して、担当者の診断結果と関連する PSI データの部分的な特徴を各チャンネルのフィルタで学習しつつ、かつチャンネルで和をとることにより PSI の相互関係を考慮した検出器を実現できる。

また、 b^k は時系列データの種類の依存しない k 番目のフィルタに対応するバイアス項である。出力 z_{0t}^k の活性化度を調整するパラメータであるため、間接的にフィルタの感度を規定している。AI モデルでは、畳み込み演算の結果 z_{0t}^k に対して活性化関数 $\tanh$ を適用し、その出力ベクトル $v_{conv} = \tanh(z_{0t}^k)$ を次層に伝播する。

次の全結合層（FC1）では、学習した k 個のフィルタの情報を 1 つに集約する処理を実行する。具体的には、 $k((T-D)/s + 1)$ 個の列と $(T-D)/s + 1$ 個の行を持つパラメータ行列 W_1 に対し、以下の線形演算を実行する。

$$z_1 = W_1 \cdot v_{conv} + b_1.$$

ベクトル v_{conv} と行列 W_1 の積によって、フィルタで検出した $k((T-D)/s + 1)$ 個の特徴量を $(T-D)/s + 1$ 個まで減らしながら情報を集約する。ここで、 b_1 は $(T-D)/s + 1$ 次元ベクトルのバイアス項である。畳み込み層と同様に b_1 は出力 z_1 の活性化度を調整する。次層へは活性化関数 $\tanh$ を適用したベクトル $v_{fc1} = \tanh(z_1)$ を伝播する。

最後の全結合層（FC2）では、1 つに集約されたフィルタの情報を問題在庫の深刻度に関連付ける処理を実行する。問題在庫の深刻度が $\{C_1, \dots, C_m\}$ の m 個に分類される




図 3 教師データ（熟練担当者の診断履歴）の例

場合、 $(T - D)/s + 1$ 個の列と m 個の行を持つパラメータ行列 W_2 に対し、以下の線形演算を実行する。

$$z_2 = W_2 \cdot v_{fc1} + b_2.$$

ただし、 b_2 は m 次元ベクトルのバイアス項である。AI モデルは、当該層の出力 z_2 に対してソフトマックス関数を適用し、各深刻度 C_i の分類確率 $y_i = P(C_i|x)$ を最終的に出力する。最大確率を与える C_i が AI の予測診断となる。

以上のように、AI モデルは、製品や部品の PSI データを入力すると、畳み込み層を通した特徴検出と 2 つの全結合層を用いた深刻度の分類により、当該製品または部品の在庫を診断する仕組みとなっている。

なお、畳み込み層と最初的全結合層の後に配置されている Dropout は、AI モデルの学習時に前層の出力ユニットを一定割合でランダムに無効化する処理である。Dropout を適用することで、学習するデータへの過適合を回避しつつ、アンサンブル学習と同等の効果による汎化性能の向上を見込めることが知られている⁵⁾。

3. AI モデルの学習

担当者による在庫診断は、対象となる製品や部品が評価時点で問題在庫かどうかを判断するのが目的である。ただし、製品や部品の PSI データは終売になるまで継続して蓄積され、その状況も日々変化していくため、在庫診断もまた継続的に実施される。したがって、AI モデルが学習の対象とする、熟練担当者による品目の診断履歴データ（以下、教師データと呼ぶ）は、図 3 のように各診断対象期間の PSI 時系列データと診断結果のペアが複数存在するデータとなる。

AI モデルの学習とは、教師データに含まれるある診断期間の PSI 時系列データを入力として、図 2 のネットワークを順伝播して得られる AI モデルの予測診断と、当該診断期間の実際の診断結果との誤差を最小化するようにモデルの各層のパラメータを更新することである。

表 1 実験の前提条件

教師データ数	851	フィルタ幅 D	20
テストデータ数	20	フィルタ数 k	40
訓練用データ数	831	Dropout1 率	0.7
学習回数	1,000	Dropout2 率	0.5
(内、エポック数)	50	カテゴリ数 m	6
バッチサイズ n	30	$w^{k,c}, W_i$ 初期値	He ⁶⁾
時系列データ長 T	90	b^k, b_i 初期値	0
チャンネル数 c	3	最適化手法	Adam
スライド s	1	学習率	0.01

本研究では、この誤差として分類タスクで広く使用されている下式の交差エントロピー誤差 E を採用した。

$$E = -\frac{1}{n} \sum_{j=1}^n \sum_{i=1}^m t_{ij} \log(y_{ij}).$$

ここで、 y_{ij} は j 番目の教師データに AI モデルを適用したときの深刻度 C_i の分類確率であり、 t_{ij} は j 番目の教師データに対する実際の診断結果 (one-hot 表現) である。 n は学習に用いた教師データの数 (バッチサイズ) である。誤差を最小化するためには、AI モデルの各パラメータで E を微分し、確率的勾配法などの最適化手法を適用する。微分の計算には誤差逆伝播法を使用する。

4. 診断精度の評価実験

現行の AI モデルの汎化性能を検証するため、消費財メーカーから提供された教師データを用いて在庫診断精度を評価した。教師データは、249 製品の各 459 日分の PSI データを対象に熟練者が作成した診断期間と診断結果のペアから構成される。診断結果は、診断期間ごとに問題の深刻度に応じて 6 種類のラベルの中から 1 つを選択する形で付与されている。1 つの製品に対して少なくとも 1 つの診断期間と診断結果ラベルのペアが存在する。

評価実験では、担当者が直近 90 日の PSI データに基づき在庫診断をする想定で、データ期間の最新日から遡って 90 日以内に診断結果が存在する 20 製品をテストデータとして選定した。選定品目の直近 90 日間の PSI データを入力して得られる AI モデルの予測診断と、当該期間の実際の診断結果を比較して汎化性能を評価する。

実験の前提条件を表 1 に示す。実際の診断期間にはばらつきが存在するため、90 日より長い診断期間については期間の分割や短縮、短い診断期間については延長をして 249 製品のすべての診断期間が 90 日となるよう事前に調整した。調整後の教師データの総数は 851 である。

実験結果として、学習回数ごとの診断精度の推移を図 4 に示す。図 4 から学習回数の増加にしたがい訓練用デ




図 4 学習回数ごとの診断精度の推移

ータの精度が徐々に向上していることが分かる。これは、在庫診断時に判断の要点となる PSI の推移や相互の関係を AI モデルが教師データから学習していることを示している。学習に用いた訓練用データについては最終的に 70%~90% の高い精度で予測できるようになる。

一方、学習に用いていないテストデータに対する診断精度については、学習過程の前半では精度が向上する傾向にあるものの、学習の中盤以降は 50% 前後の精度で停滞した。これは AI モデルが訓練用データに過適合している可能性を示唆している。しかし、高い Dropout 率を設定していること、およびフィルタ数を 10 に減らしても汎化性能が改善しなかったことなどから、過適合の原因としては、教師データ数の不足や診断結果の偏り、あるいはモデルのネットワーク構成の問題と考えられる。

5. 今後の課題と見通し

評価実験の結果を踏まえ、AI モデルを実務で活用できるようにするには、汎化性能の向上と問題在庫の解消に役立つ診断根拠の説明の 2 つが今後の課題となる。

汎化性能については、実務では 80% 以上の診断精度が求められる。現状の精度の頭打ちは、AI モデルの過適合が主な原因と思われるため、教師データの追加やデータ拡張による機械的な水増し、および AI モデル改良の両面から対策を進める。特にモデルの改良では、まずは入力層でのチャネルの見直しを検討している。現行の AI モデルでは、PSI 時系列データからそのまま 3 つのチャネルを構成しているが、実際の在庫診断では、例えば販売の増減傾向を判断する際に診断期間内の移動平均値が用いられる場合も多い。こうした状況をモデルに反映するため、販売の移動平均系列 S' を別途入力に加え、 $PSS'I$ 時系列データの 4 チャネル構成とするような工夫を考えている。

診断根拠の説明については、CNN などのディープラーニングは特徴量から人間が理解可能な形で判断根拠を説明するのが困難であることが知られており、近年では主にネットワークの出力に貢献する特徴量を明確にすることで、判断根拠を説明する手法が研究されている⁷⁾。こうした既存研究を参考に、本研究では AI モデルが出力した診断結果に対する各フィルタの貢献度から診断根拠を説明する手法の開発も並行して実施している。

6. おわりに

本報告では、担当者の経験に依存して生じる在庫診断時の判断のばらつきが、問題在庫の見逃しや解消遅延につながるという課題に対して、熟練担当者の診断ノウハウを学習した AI による自動診断技術を紹介した。

消費財メーカーの実データから作成した教師データを用いて AI モデルの汎化性能を評価した結果、約 50% の診断精度が得られた。今後は汎化性能の向上や、担当者にとって有用な診断根拠の説明を実現していく。

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) Y. Kim: Convolutional Neural Networks for Sentence Classification, In Proc. of EMNLP 2014, (2014)
- 3) C. Szegedy, et al.: Going Deeper with Convolutions, In Proc. of CVPR 2015, (2015)
- 4) 斎藤康毅：ゼロから作る Deep Learning，オライリー・ジャパン，(2016)
- 5) Pierre Baldi, et al.: Understanding Dropout, In Proc. of NIPS 2013, (2013)
- 6) K. He, et al.: Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification, In Proc. of ICCV 2015, (2015)
- 7) R. R. Selvaraju, et al.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, In Proc. of ICCV 2017, (2017)



宗形 聡 2003 年入社
ビジネスインキュベーション部
機械学習・AI を用いた意思決定支援
技術，データ分析技術の研究開発
satoshi.munakata.tu@hitachi-
solutions.com



清藤 駿成 2017 年入社
ビジネスインキュベーション部
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
takanari.seito.cw@hitachi-
solutions.com