

IoT と AI による製造業の生産性の向上

Application of IoT and AI to productivity improvement for manufacturers

IoT と AI を活用することで様々な付加価値を生み出すことが可能である。(株)日立ソリューションズ東日本では製造業向けに IoT と AI による生産性向上ソリューションを提供している。IoT で製造ラインの状況を収集し複数工場、複数ラインの稼働状況を可視化することで、作業順序見直しや設備シェアリングを行い、アイドル時間を削減できる。また、非稼働要因分析、製品不良予兆検知、設備故障予兆検知により予防保全することで故障等による非生産時間を削減可能となる。AI の活用には業種・業務知識、データサイエンス、データエンジニアリングのスキルが必要である。HSE では日立認定データ・アナリティクス・マイスターをはじめとする AI 開発体制を保有し、お客様ニーズに合致した生産性向上ソリューションを提供している。

手塚 大 Tezuka Masaru
及川 慎也 Oikawa Shinya
佐々木 和也 Sasaki Kazuya
加地 拓己 Kachi Takumi
南雲 陸 Nagumo Riku

1. はじめに

様々なモノが接続されたネットワークをInternet of Things (IoT)¹⁾と呼ぶ。自動車、家電、工場の製造設備など様々なモノがデジタル技術によってIoTに接続されている。これらのモノの多くにはモノの内部状態や外界の情報を取得するためのセンサが取り付けられており、センサの測定値がデータとしてIoTに送信され蓄積され活用される。また多くのモノにはアクチュエータが取り付けられ、IoTから受信したデータによってモノの動作を制御できるようになっている。多くのモノがIoTに接続できるようになってきており2020年には300億個以上のモノが接続されるという予測もある²⁾。

IoTによって多くのデータが蓄積されると、そのデータを活用して付加価値を生み出すことが可能になる。データ活用の一つに、人工知能 (AI) の技術を用いて大量のデータから学習によって何らかの役立つモデルを構築する方法がある。例えば過去の設備の故障データから学習により故障予兆モデルを作ることによって設備の故障発生を予測し、予防保全に活用することができる³⁾。

実用的なAIシステムは統計分析や機械学習の様々な手法を組み合わせ、特定の用途向けに構築される⁴⁾。

2. 稼働率、可動率と生産性

IoTとAIを活用して生産性を向上したいという要望が増えてきている。

図1に示すように工場の操業時間は設備を運転している時間とアイドル時間に分けられる。設備の稼働率は

$$\text{稼働率} = \text{設備運転時間} \div \text{操業時間} \quad (1)$$

で定義される。また、設備運転時間内にも実際には図2のように、不良品のリワーク時間、段取替えの待ち時間、チョコ停（短時間の停止）、故障などの実生産をしていない時間がある。設備運転時間に占める実生産時間を可動率と呼ぶ。

$$\text{可動率} = \text{実生産時間} \div \text{設備運転時間} \quad (2)$$

可動率は稼働率と区別するために「べきどうりつ」と読

設備運転時間	アイドル時間
操業時間	

図1 稼働率

実生産時間	リワーク	段取替	チョコ停	故障
設備運転時間				

図2 可動率

表1 データ蓄積レベル

蓄積 レベル	蓄積時間 目安	できること
1	導入～	現状の見える化 BI活用
2	1ヶ月～	非稼働要因分析
3	3ヶ月～	製品不良予兆検知
4	6ヶ月～	設備故障予兆検知 (正常からの逸脱検知)
5	1年～	設備故障予兆検知

むこともある。

生産性⁵⁾とは単位時間当たりの生産量であるから、生産性を上げるには稼働率と可動率の両方を上げる必要がある。

稼働率を上げるにはスケジューリングによってアイドル時間を減らす、リソースシェアリングにより空き時間に別の製品を生産するなどしてアイドル時間を減らすなどの方法が取られる。また、下記の方法で可動率を向上させることができる。

- ・不良品の発生を減らすことによるリワーク時間削減
- ・作業標準化による段取り作業時間の短縮と、作業順序最適化による段取り発生の削減
- ・さまざまなチョコ停原因の対策によるチョコ停削減
- ・予防保守による故障発生の削減

(株)日立ソリューションズ東日本（以下、HSE）はIoTとAIを活用して生産性を向上するためのソリューションを提供している。ネットワークに接続された製造設備からのデータを活用し、主に可動率の向上を行う。ソリューションの詳細を次節以降で紹介する。

3. IoTとAIによる生産性向上ソリューション

3.1 データ蓄積レベル

IoTによって製造設備からのデータを取得し始めると次第にデータの蓄積量が増えてくる。データ蓄積量が増えるにつれて「できること」が増えてくる。表1にデータ蓄積レベルとできることのおよその関係をまとめた。以下、この表に沿ってIoTとAIを活用した生産性向上ソリューションを説明する。

なお、表中の蓄積時間は目安であり、業種、業務、設備数、操業時間などによって異なる。



図3 人の作業データ取得




図4 現状の見える化

3.2 現状の見える化

製造設備のデータ取得をはじめてすぐに実現可能なのが表1の蓄積レベル1にあたる現状の見える化である。

設備のデータを取得するIoTデバイスとして最も導入が容易なのが積層信号灯である。多くの製造設備に接続が可能であり、信号灯の点灯状況をデータとして送信する機能を持つものもある。例えば緑点灯は実生産中、赤の点滅はチョコ停、赤の点灯は故障停止、全消灯はアイドルのように設定して用いる。

また、人の作業状況の取得には図3に例示するようなサイコロ型デバイスやスマートフォン、タブレット端末などが活用できる。

サイコロ型デバイスは立方体であり6面にそれぞれ作業名称が書かれている。作業者は現在行っている作業が書かれている面を上にしておく。どの面が上を向いているかの情報がネットワークに伝えられる。

スマートフォンやタブレットには作業記録用のアプリをインストールし、そのアプリで現在行っている作業を記録する。

サイコロ型デバイスは、操作方法が直感的で習熟が容易であり、手袋などを装着していても操作できるため粉塵や油汚れがあるような環境でも利用できるが、一つのデバイスにつき6種類の作業情報しか記録できない。スマートフォンは作業情報を詳細に記録できるが、環境によっては利用できないことがある。

データ蓄積レベル1では、図4に示すように行燈（ア

ンドン) ⁵⁾を用いた現状の可視化や、BIツールの活用ができる。

アンドンは工場のレイアウトマップ上に積層信号灯の点灯状況を表示するもので、工場内のどこで何が起きているかをリアルタイムで把握することができる。アンドンの画面をモニタすることでチョコ停などへの迅速な対応が可能となる。また、BIツールを使うことで、例えばチョコ停の発生頻度の高い設備の特定、設備停止時の作業員到着待ち時間の分析などができる。

また複数工場の状況をリアルタイムで把握し設備シェアリングを進めることでアイドル時間を削減し、稼働率を向上させることができる。

3.3 非稼働要因分析

チョコ停は様々な設備で様々な理由で発生する。このため一度にすべてのチョコ停原因を解消するのは難しい。生産は工程順に複数の設備でおこなわれる。製造工程が合流や分岐する場合もある。また工程間にバッファとして仕掛在庫が置かれる。このため、設備が停止してもライン全体のサイクルタイムに影響を与えない場合もある。逆にある設備の停止が波及的に他の設備に影響を与えライン全体に悪影響を及ぼす場合もある。そこで、最も改善効果の高いチョコ停原因から解決していく。この改善の優先度を付けるのが表1のレベル2にある非稼働要因分析である。データ蓄積が進み1ヶ月程度が経過すると非稼働要因分析ができるようになる。

非稼働要因分析はAI技術であるベイジアンネットワークや決定木を用いて行われる。IoTによって蓄積された設備稼働データをもとにサイクルタイムの低下に与える設備・要因ごとの影響度を算出する。分析結果は図5のようなトルネードチャート⁶⁾で示される。

トルネードチャートは一つの要因の改善及び悪化に対するライン全体の改善率と悪化率を同時に表す。ライン全体への影響度の高い要因がチャートの一番上に表示され、下に来るほど影響度は小さくなる。竜巻のように見えることからトルネードチャートと呼ばれる。このチャートを見て、ライン全体への影響が大きい要因から改善施策を行うことで効果的にチョコ停による非生産時間を削減し、可動率を向上させることができる。

分析のためには設備が停止した時の停止理由データも取得・蓄積されている必要がある。停止理由は例えばプログラマブルロジックコントローラ(PLC)⁵⁾やコンピュータ数値制御機器(CNC)⁵⁾から取得できる。また、ス




図5 トルネードチャート




図6 不良発生をニューラルネットワークで学習

スマートフォンやタブレットのアプリから作業員が入力するという手段もある。

3.4 製品不良予兆検知

IoTによるデータ蓄積が進み、不良品が発生した時の製造データの量が十分になると製品の不良発生を予測する不良予兆検知ができるようになる。これが表1のレベル3にあたる。

例えば1日あたりの生産量が1,000個、不良発生率が0.05%の場合、90日（約3か月）で45個の不良が発生する。この45事例を不良発生教師データとしてAIを学習させ、不良発生を予測することができる。不良事例数の45は必ずしも十分な数ではないが、継続してデータを蓄積していくことで次第に予測精度は高まっていくので、まずは始めることが重要である。

図6は不良発生を学習したニューラルネットワークの例である。実際にはユーザがこのネットワークを目にすることはなく、システムの内部でこのようなネットワークで不良予兆検知の計算が行われる。不良の発生が予測されると担当者に警告メールを送信したり、後述する予兆統合アンドンという画面で警告を表示したりする。




図7 予兆統合アンドン

3.5 設備故障予兆検知

設備の故障は通常はめったに発生しない。このため、設備の故障予兆検知ができるようになるには、長期間のデータ蓄積が必要である。例えば教師あり学習で設備故障を予測するには少なくとも20程度の故障事例のデータがあることが望ましい。しかしそのためには1年～数年のデータ蓄積が必要になる。

そこまで待たなくても半年～1年程度のデータを用いて「正常状態からの逸脱」を故障として検知する手法がある。表1のレベル4がこの段階にあたる。正常時の複数のセンサ間の相関関係を学習し、相関関係が正常時と大きく異なったときに、異常発生として警告する方法である。

データ蓄積が進み、十分な故障事例データが集まった段階が表1のレベル5であり、教師あり学習で高い精度で故障発生の予測が可能となる。

3.6 予兆統合アンドン

製品不良予兆や設備故障予兆では、予兆が検知されるとメール等で担当者に警告が送られる。また、図7のような「予兆統合アンドン」という画面で警告が表示される。従来のアンドンでは現時点での設備の稼働状態だけを表示するが、予兆統合アンドンでは未来の予兆も合わせて表示する。

予兆統合アンドンは3.2節、図4で説明した「現状の見える化」を行うアンドン画面に予兆警告情報やその他の




図8 システム開発から運用までの流れ

計画情報などを合わせて表示する画面である。工場のレイアウトマップ上に実際の設備に位置に合わせて現状と予兆の情報を表示する。

図7の例では箱詰め装置を拡大して示しているが、この装置は現在自動運転中である。計画情報をもとに、現在のペースで作業を進めると段取り替えが30分以内に発生することを表示している。また、現時点では製品不良発生の予兆はないが、設備故障の予兆が検知されている。主軸に異常な振動が発生しているという補足情報も表示される。

この予兆統合アンドンの情報を見て先手で対策を打つことで、リワークや故障による非稼働時間を削減し、可動率を向上させることができる。

3.7 生産性の向上

ここまで述べたようにIoTとAIを用いた本ソリューションを用いると稼働率と可動率を向上できる。

- ・ IoTで状況を収集、アンドンで可視化し問題発生に即応。非生産時間を削減し可動率を向上。
- ・ 複数工場、複数ラインの稼働状況を把握。作業順序見直しや設備シェアリングによりアイドル時間を削減し稼働率を向上。
- ・ 非稼働要因分析によりライン全体への影響度の高い要因から改善。チョコ停による非生産時間を効率的に大幅削減し可動率を向上。
- ・ 製品不良予兆検知で事前対策し不良発生を低減。リワークによる非生産時間を削減し可動率を向上。




図9 特徴量の例

- ・ 設備故障予兆検知により予防保全することで故障による非生産時間を削減し可動率を向上。
以上により生産性の向上を実現する。

4. システム開発から運用開始まで

IoTとAIを用いた生産性向上ソリューションの、システム開発から運用開始までの流れを図8に示す。平均的なケースで要件定義から運用開始までおよそ6ヶ月程度となる。

AIを利用するシステムの開発で特徴的なのが「分析モデル構築」工程である。この工程を細分化すると「課題理解・データ理解」「特徴量設計」「モデル選択」「検証・評価」となる。

「課題理解・データ理解」ではIoTから得られるデータや、その他の業務システムから得られるデータを理解し、どのように組み合わせて活用できるかを検討する。データのクレンジングなども行う。

「特徴量設計」がAI活用で最も重要な作業となる。特徴量の例を図9に示す。IoTデバイスから得られた生データを直接AIに入力するのではなく、例えば立ち上がりの時間や信号のピーク値の間隔などに変換して入力するほうが予兆検知能力や学習精度が高まる。どのような特徴量を用いると良いかは問題によって様々である。そこでデータアナリストが特徴量の設計を行う。

AIは統計分析や機械学習などの技術の組み合わせで実現される。例えば機械学習でもニューラルネットワークや決定木などの様々な学習モデルがあり、さらにニューラルネットワークにも深層学習（ディープラーニング）⁷⁾などのいくつかのモデルがある。問題に合わせて適切なモデルを選択⁸⁾するのが「モデル選択」である。

設計した特徴量と選択したモデルで期待通りの結果を出せるかを「検証・評価」する。評価結果に基づき「特徴量設計」と「モデル選択」を繰り返し、分析モデルを構築する。




図10 IoT・AI システムの開発に必要なスキル

IoTとAIを活用するシステムの開発には図10に示すような「業種・業務知識」「データサイエンス」「データエンジニアリング」の三つのスキルが必要とされる。例えばデータの理解には業種・業務知識が必要であり、データクレンジングにはデータエンジニアリングのスキルが必要である。また特徴量設計には業種・業務知識とデータサイエンスの両方のスキルが必要となる。検証・評価では統計的に正しい評価のためにデータサイエンスのスキルが必要であるが、同時にビジネス上の価値を評価するために業種・業務知識も必要である。HSEではこれらのスキルを持った人材を多く抱えAI開発体制を保有している。

また、日立グループでは次の二つの能力を持つ人材を日立認定データ・アナリティクス・マイスター（以下、HDAM）として認定している。

- ・ 顧客の要望を的確に把握し、その要望を数値分析の対象として変換でき、データサイエンティストに分析を依頼し、データサイエンティストが実施した結果をもとに有効と思われるビジネスアクションを創出できる。
- ・ 業務知識、業務要件定義、分析技術の選定、分析（数理統計）の能力を兼ね備え、ある特定業務もしくは複数の業務について、一連の作業を達成し、アナリティクスサービスをリーダーとして実施できる。

HSEは多数のHDAM認定者を擁し、お客様ニーズにあったIoT・AI活用システムの開発に取り組んでいる。

5. 今後の展開

現在、要件定義、システム開発から運用までおよそ6ヶ月の期間を要している。

HSE では、これまでの多数のソリューション提供経

験をもとに、分析機能の共通化、特徴量設計やモデル選択の自動化技術の研究開発を進め、クラウドサービスとしてのソリューション提供を準備している。今後、クラウドサービスとしての提供により運用開始までの期間を大幅に短縮する計画である。

6. おわりに

IoT で設備と人のデータを収集し、蓄積されたデータを AI やデータ分析技術を用いて有用な情報に変換し活用することで工場の生産性を向上させることができる。IoT を導入しデータの蓄積レベルが上がるにしたがって、現状の見える化、非稼働要因分析、製造物の不良予兆検知、製造設備の故障予兆検知と活用の幅が広がっていく。

AI を活用するシステムの開発では、一般の情報システム開発にはない「分析モデル構築」という工程がある。ここでは特徴量の設計とモデルの選択を繰り返し、顧客業務課題の解決に最適な AI による分析モデルを構築する。この構築には業種・業務知識、データサイエンス、データエンジニアリングのスキルが必要である。

HSE では HDAM 認定者をはじめ技術力の高いアナリスト、エンジニアによる開発体制を保有し、お客様ニーズに合致した IoT と AI を用いた製造業の生産性向上ソリューションを提供している。

また、将来はこのソリューションをクラウドサービスとして提供する予定である。

参考文献

- 1) F. Mattern, C. Floerkemeier: From the Internet of Computer to the Internet of Things, Informatik-Spektrum, 33 (2), pp. 107–121, 2010.
- 2) Internet of Things (IoT) connected devices installed base worldwide from 2015 to 2025 (in billions), Statista, November 2016, <https://www.statista.com/statistics/471264/iot-number-of-connected-devices-worldwide/> (Accessed 2018.8.27)
- 3) 井手 ほか：異常検知と変化検知，講談社，2015.
- 4) N. J. Nilsson: The Quest for Artificial Intelligence, Cambridge University Press, 2015.
- 5) APICS：サプライチェーンマネジメント辞典 APICS ディクショナリー対訳版，第 15 版，生産性出版，2018.
- 6) R. T. Clemen ほか：One-Way Sensitivity Analysis: Tornado Diagrams in Making Hard Decisions With

Decision Tools, third ed., South-Western Pub., pp. 191–194, 2013.

- 7) 麻生ほか：深層学習，近代科学社，2015.
- 8) 下平ほか：モデル選択，岩波書店，2004.



手塚 大 1994 年入社
アナリティクスソリューション部
アナリティクス事業の推進
masaru.tezuka.fd@hitachi-solutions.com



及川 慎也 1991 年入社
アナリティクスソリューション部
アナリティクス事業の推進, IoT, AI
活用コンサルティング
shinya.oikawa.ze@hitachi-solutions.com



佐々木 和也 2004 年入社
アナリティクスソリューション部
アナリティクスソリューションの企画，設計，開発，顧客提供
kazuya.sasaki.kk@hitachi-solutions.com



加地 拓己 2007 年入社
アナリティクスソリューション部
アナリティクスソリューションの企画，設計，開発，顧客提供
takumi.kachi.zt@hitachi-solutions.com



南雲 陸 2016 年入社
アナリティクスソリューション部
分析モデル構築，アナリティクスサービスの顧客提供
riku.nagumo.uh@hitachi-solutions.com