

KYBの生産技術領域におけるAI×IoTの取り組み

内 藤 孝 昌

1 はじめに

近年、AI（Artificial Intelligence：人工知能）とIoT（Internet of Things：モノのインターネット）が学术界やIT（Information Technology：情報技術）業界のみならず、医療や製造業などあらゆる分野において世界中で注目を集めている。

そして、その流れは着実に日本の製造業にも押し寄せている。日本の製造業は伝統的に現場中心となっており、匠の技による高品質な製造や、カイゼンと呼ばれる現場中心の生産性向上に強みがある。そのため、ドイツや米国と比べてAIやIoTへの取り組みが遅れていたが、日本の深刻な労働力人口減少や米国のデジタル技術を活用した自動車業界への新規参入などをきっかけに、大きな危機感が生まれ、急激に変革が進みつつある。その用途は、自動運転などの製品への活用と、品質判定や予知保全といった生産現場への活用の両面で進んでおり、市場における企業間の競争がますます激化している。

また、AIやIoTといったデジタル技術への注目に伴い、いわゆるDX（Digital Transformation）人財^{注1)}や先端IT人財と呼ばれる人財の需要が高まっており、年々人財不足が進んでいる。経済産業省の調査¹⁾によると、その不足数は2030年には55万人まで拡大すると試算されている。

こういった産業の変化に伴い、KYBにおいてもAI×IoTを活用した、革新的モノづくりを進めている。本報では、KYBの生産技術領域における従来ITシステムの歴史をふまえ、革新的モノづくりの一部である近年のAI×IoTの取り組み事例を紹介する。さらに、それらを継続的に推進するための、社内のDX人財育成の取り組みや、DX専門組織の設立について紹介し、当社の生産技術領域の方向性について示す。

注1) KYBでは「人材」を「人財」としている。そのため本報においては以後全て「人財」と記載する。

2 従来システムの紹介

当社における生産技術領域へのIT活用の歴史は古く、数十年前から内製中心でITシステム開発・導入を進めてきた。この取り組みの歴史や課題は、近年のAI×IoTの取り組みを語る上で欠かせないため、AI×IoT活用事例の紹介の前に一部紹介する。

2.1 POPICS^{注2)}（図1）

当社の生産ラインには20年以上前²⁾から、POPICSと呼ぶ、いわゆるMES（Manufacturing Execution System：製造実行システム）を内製開発し、導入している。POPICSはラインに設置したパネルコンピュータを通して、生産指示といった上位側からの情報転送の他に、設備のI/Oを利用したサイクルタイムの収集や、作業による不良実績報告などの下位側からの情報収集を実施している。さらに、工具の使用頻度などを収集することで、工具交換時期の最適化を行うなど、KYBの生産ラインにおいて必須のシステムとなっている。また、収集した情報を生産性などのKPI^{注3)}として集計し、管理者などに見える化アプリケーションとして提供している。

ライン Aライン										EIA 10/30 11:02:11	
No	背番号	ロットNo	計画	投入	良品	不良	実績 CT	人員	進度	良品累計	
1	KYB1	LOT1	1	1	1	0	0.0	4.00	●	43	
2	KYB2		50	47	42	0	15.2	4.00	▲		
3	KYB3		4	0	0	0	0.0	4.00			
4	KYB4		66	0	0	0	0.0	4.00			

非稼働発生

経過時間 0時間 9分
機械故障(専門保全)

生産開始 生産終了

メニュー
生産実績編集
不良実績編集
非稼働実績編集

ライン異常入力
仕様表示
ライン切替
言語切替

図1 POPICSの画面例（データはサンプル）

しかしながら、基本コンセプトは当初からあまり変わっておらず、基本収集単位が「ライン」である。そのため、「設備」単位の情報は一部を除き扱えず、設備の不具合対策への利用などのニーズに対応できないシステムとなっていた。

注2) Point of Production Information Collection Systemの略

注3) Key Performance Indicatorの略で、目標の達成度を評価するための主要業績評価指標のことをいう。

2.2 検査支援システム (図2)

当社では検査工程の自動化を進めているものの、依然として手作業による検査工程が残っている。本システムはそのような検査工程において、検査漏れや判定基準の間違いを防止する目的で、2009年に内製開発した³⁾。

仕組みとしてはシンプルで、無線の送信機をノギスやハイトゲージといった各種計測機器に取り付け、計測値をパネルコンピュータに送信するというものである。パネルコンピュータ上のソフトウェアは、送られてきた計測値からOK/NGなどの判定を自動で行い、同時に実績をデータベースに保管する。

本システムは大きな効果があるものの、評価している値は計測値そのものであるため、計測可能なものに限られている。そのため、目視検査など人間に頼っている工程には適用が不可能であった。

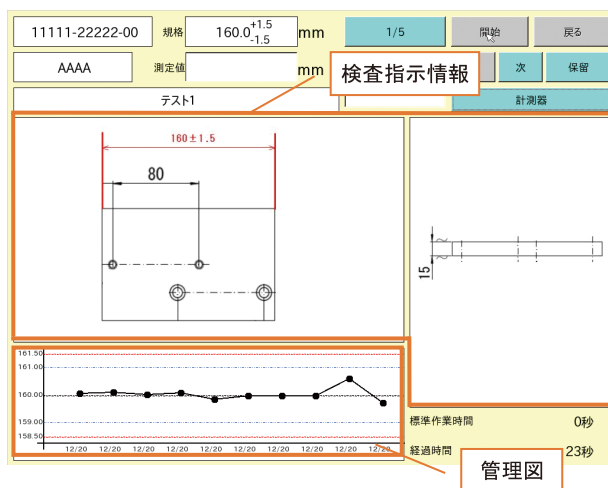


図2 検査支援システムの画面例

3 革新的モノづくり

現在、主力製品であるショックアブソーバ工場の生産ラインを中心に、「革新的モノづくり」を推進している。この活動では、AI×IoTを積極的に活用し、設計から生産までのモノづくりシステムを再構築することで、良品品質を維持できる「世界No.1のショッ

クアブソーバ工場」を目指しており、数値目標として以下を掲げている。

- ①生産性2倍
- ②設計～生産リードタイム1/2
- ③不良ゼロ化

特に生産技術領域においては、図3のロードマップに示す通り、人を介在させない完全無人化の生産システムの実現という高い目標を掲げており、現在は第二期を実施している段階である。

次章では、この革新的モノづくりの一部として取り組み事例を4つ紹介する。特に後半2つは著者が中心に取り組んだ事例であるため、より詳細を紹介する。

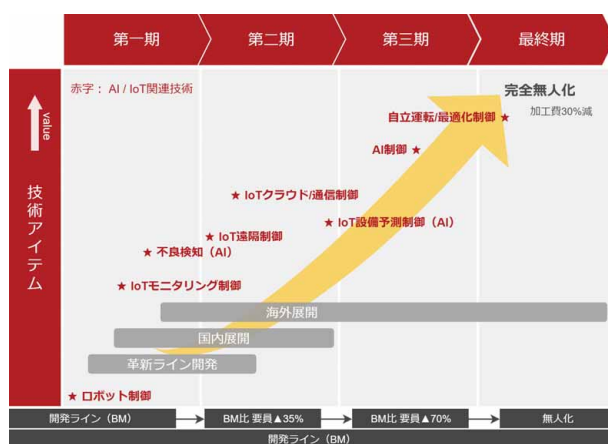


図3 ロードマップ (生産技術領域)

4 AI×IoTを活用した代表事例紹介

4.1 生産ライン見える化

2.1で紹介したPOPICSの改良版の位置づけとして、生産ライン見える化システムの開発・導入を進めている。従来のPOPICSではライン単位の情報の見える化しかできないという問題があったが、本システムでは各設備の制御を行っているPLC (Programmable Logic Controller) が情報を収集し、ライン内の大型モニタや工場内のサーバにて設備単位の情報見える化を実現している (図4)。2019年11月7日現在、6ラインまで

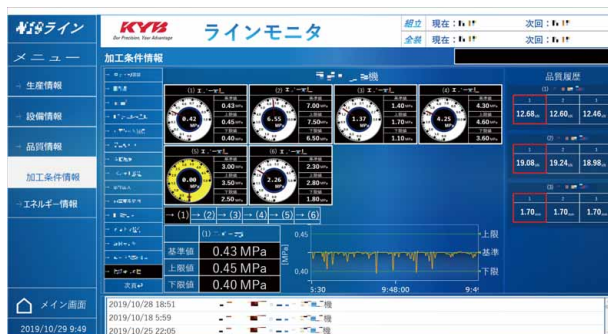


図4 ラインモニタの画面例 (一部モザイク処理)

展開完了している。

今後はクラウドへの移行を検討し、世界中のラインが同じシステムで横並びに確認できる体制とし、生産性向上や不良率低減のための分析ツールとして活用していく計画である。

4.2 画像処理による外観検査

当社では、比較的検査が容易な外観検査には展開性の高い市販の汎用外観検査装置を導入するが、市販品での検出が困難な場合には、主に生産技術研究所の画像処理技術者による内製開発で対応している。

例えば図5は黄色の部分に欠陥があるが、この外観検査装置の開発は内製にて行った⁴⁾。基本的には検査部位に合わせた光学系（カメラ、照明など）の選定から撮影画像に対する特徴抽出、AIなどを活用した判定モデルの開発までトータルで実施している。

また、量産導入にまで至っていないものの、近年は比較的新しいAI技術であるGAN（Generative Adversarial Networks：敵対的生成ネットワーク）などを活用し、良品画像のみから学習させた判定モデルを用いて、不良判定を行うといった試みも実施している。




図5 ロッドパッキン不良品

4.3 溶接不良検知

4.3.1 背景・目的

アーク溶接の代表的な不良（欠陥）は、外観での品質判定が比較的容易な「表面欠陥」と、外観での品質判定が困難な内部に欠陥が発生する「内部欠陥」の二種類に大別できる。前者の例は「狙い位置ずれ」や「アンダーカット^{注4)}」、後者は「ブローホール^{注5)}」や「溶込み不良」などがある。従来は外観検査に頼る部分が大きく、低コストで内部欠陥までを自動判定することが困難であり、定期的な破壊検査などが必要となっていた。

そこで、画像などの外観情報ではなく、溶接時の

電流値など複数のセンサデータを時系列データとして取得し、AIによって品質を判定する内製システムの実現を目指した。

注4) 溶接ビードの止端部が母材表面よりも凹んでいる状態のこと。

注5) 溶接金属内にガスが残留することなどが原因で、空洞が生じたもの。

4.3.2 システム概要

図6に開発したシステムの概略図を示す。リアルタイム判定を実現するために、データ収集だけでなくAIによる自動判定もライン内のエッジコンピュータ^{注6)}にて行っている。また、本報では詳細を割愛するが、アーク溶接以外にプロジェクション溶接に関しても同様の試みを実施している。そのため、それぞれの判定結果を1台のエッジコンピュータに集約し、一括で見える化を行う構成としている。

注6) データをクラウドで処理するのではなく、発生源に近い場所（エッジ）で処理する考えを、エッジコンピューティングと呼び、それを担うコンピュータのことをエッジコンピュータと称する。

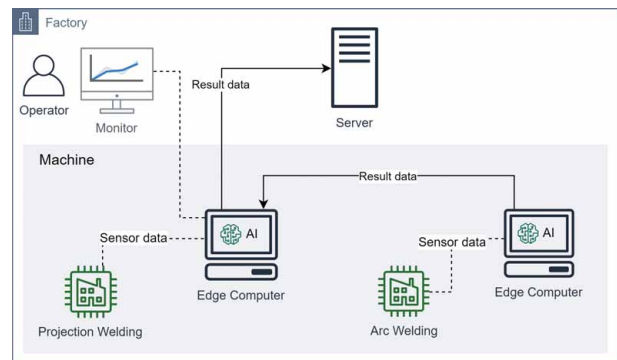


図6 溶接不良検知システム概略図

4.3.3 開発結果

溶接電流の時系列波形の例を図7に示す^{注7)}。この図は1,000本の良品波形を灰色、1本の不良品波形を赤色で表している。図のように、不良品波形は1,000本の良品波形のバラツキの範囲内に含まれており、電流値の上下限の閾値設定など単純な判定基準では対応できないことが分かる。

良品データのみを利用して学習させたAIモデルを利用し、50本の不良品と約15,000本の良品で評価した結果、表1の精度となった。誤判定率0.00%というのは、「不良を一切見逃さない」状態である。そして、良品を誤って不良品として判定してしまう割合である過検出率も、0.28%と非常に低く精度の高い不良検知システムであることが確認できた。

注7) 各軸の具体的な数値は非公開としている。




図7 溶接時の電流波形の例

表1 不良検知性能評価結果

評価項目	結果
誤判定率 [%]	0.00
過検出率 [%]	0.28

4.3.4 残った課題

本システムは予定通り「内部欠陥」の自動判定が実現できたが、一方で「狙い位置ずれ」などの「表面欠陥」の一部を判定することができなかった。そのため、次の対策として「表面欠陥」は画像処理などの外観検査によって行い、組み合わせによって全不良を自動判定する方向で開発を進めている。

4.4 予知保全

4.4.1 背景・目的

現在、社内の設備保全方法は、故障した時に保全する「事後保全」と故障前に定期的に保全する「予防保全」が中心となっているが、前者は故障による生産性の低下、後者は過剰保全による保全コスト増などが懸念される。しかしながら、設備の状態を監視して故障の予兆があったときに保全する「予知保全」が、近年のIoTやAIの発展によって実現可能となってきた。

そこで、AIを使って予知保全を行う予知保全システムを開発・適用することで、設備故障に伴うライン停止と過剰保全の防止（保全コストの低減）を狙った。また、本システムをグローバルに展開させるために、小規模から大規模まで様々な環境に対して、処理能力とコストの両面で対応できるKYB-IoTプラットフォームの実現を目指した。

4.4.2 システム概要

予知保全を実現するために一般的に多く利用されるのは「振動」データであるが、対象によっては必要なサンプリングレートが10kHzを超える場合があ

る。そのため、当社で従来開発してきたようなPOPICSなどとは桁違いのデータ量が発生する。但し、対象設備によっては、1分に1回程度のサンプリングでも十分な可能性もある。つまり、大量データにも耐えうる構成を持ちながら、少量データの場合では低コストに実現できる仕組みが必要となった。

それを実現するために、パブリッククラウドのAWS (Amazon Web Services) 上に、サーバレスアーキテクチャ^{注8)}を全面採用し、弊社独自のKYB-IoTプラットフォームを構築することにした。

図8に開発したシステムの概略図の一部を示す。ごく一部を除き、ほぼ全てをサーバレスのサービスで構築することによって、処理性能もそれに伴うコストも「使った分だけ支払う（従量課金）」仕組みにできるため、規模に見合った対応が可能となる。

注8) サーバを自前で用意せず、AWSなどが管理するマネージドサービスを活用し、処理に必要なリソースを動的に設定してシステムを構築する考え方のこと。

4.4.3 システムの特徴

本システムの代表的な特徴について3つ紹介する。

(1)二段階故障判定

1つ目がエッジとクラウドの二段階による故障判定である。これは図8の「1.短期故障判定（前処理）」と「5.長期故障判定（最終判定）」という二段階の判定のことを指す。今回のようにビッグデータ^{注9)}を扱うシステムの場合、全てクラウドに送信しているとコストが肥大化してしまう。そこで、エッジ側の「1.短期故障判定（前処理）」によって、収集した瞬間の「短期的」な一次故障判定を行い、クラウドにはその「短期故障判定結果ファイル（1MB未満）」のみ送信する。そして、クラウド側では複数の「短期故障判定結果ファイル」を用いて、最終的に故障かどうかを判定（長期故障判定）する。

なお、短期故障判定もAIのモデルで実施しているが、導入後に機器交換などが発生し設備の状態が変化すると、導入当初のモデルでは性能不足に陥る場合がある。そのため、運用稼働後も頻度を落として定期的に元の生波形データをクラウドに送信する。

注9) 例えば本事例で扱ったある設備では5秒間で40MB程度の波形CSVファイルを出力する。

(2)エッジAIモデル展開機能

2つ目がAWS IoT Greengrassを利用した、エッジAIモデル展開機能である。本システムではエッジで動作させる短期故障判定用のAIモデルもクラウド上で学習している。これによって学習済モデルを一元管理しているが、これを手動でエッジコンピュータに展開して利用するというのが、最も単純です

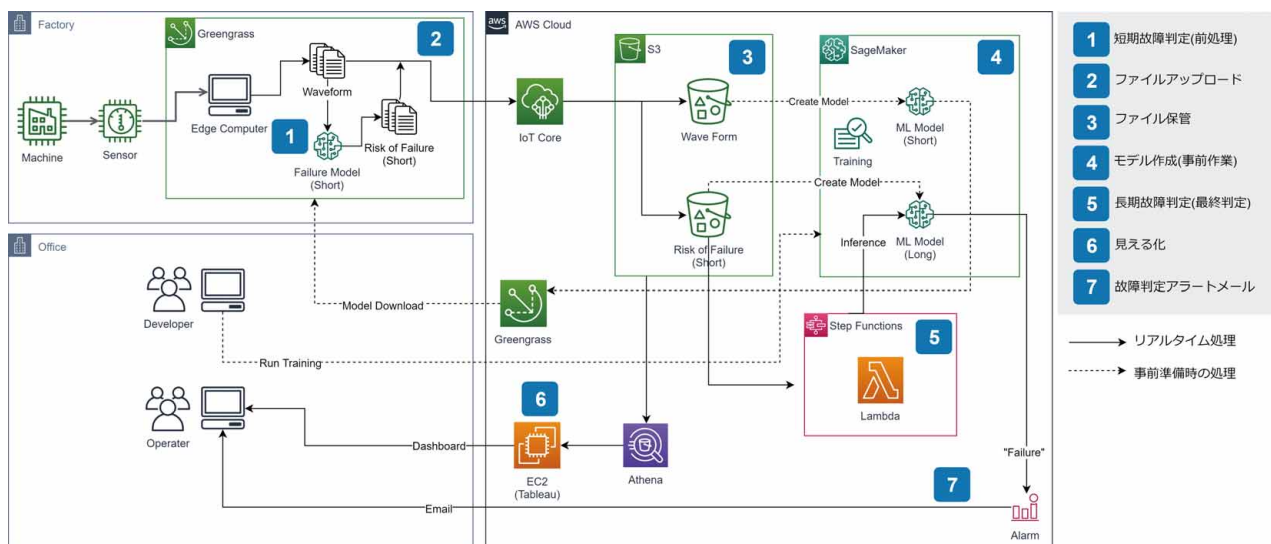


図8 KYB-IoTプラットフォーム概略図（一部）

にできる方法である。しかしながら、前述の通りAIシステムにおいて、導入当初のモデルが永続的に利用できるようなことは基本的にない。そのため、定期的に再学習をして再度展開しなおす必要があり、それを容易に実現できる仕組みが必要である。

本システムでは、そこにGreengrassというサービスを利用した。これを利用すれば、クラウド上でモデルとそれを利用した短期故障判定のプログラムを実装でき、またそれらをセットでクラウド側からエッジコンピュータに展開することが可能となる。

このサービスは、まだ発展途上な部分があり、初期のセッティングや動作要件が複雑といったデメリットもある。また、初期のプラットフォームには高機能すぎるという見方もできる。しかしながら、今後このIoTプラットフォームを全社展開した場合を想定し、運用後のAIモデル展開性の考慮は非常に重要と考え、将来を見越して本機能を採用した。

(3)高可用性

最後が高可用性、つまり止まらないシステムの実現である。サーバレスアーキテクチャについて、4.4.2の説明では低コストの部分のみ説明したが、同時に高可用性も実現することができている。従来のアーキテクチャでは、物理もしくは仮想サーバを構築し、そこでシステムを動かす。この場合、単一のサーバのみで動かすと、ハードウェア故障やネットワーク障害が発生した際にシステムが止まってしまう。そこで、仮想サーバを複数台用意して冗長化を行うのが一般的であるが、当然コストは増加する。

一方、サーバレスアーキテクチャでは仮想サーバなどを固定するわけではなく、例えばそこで動作するプログラムのソースコードのみを用意する。そして、

実行時に正常な状態の仮想サーバをランダム^{注10)}に選択し、プログラムの実行を行う。そのため、サーバが故障してもすぐに他の環境で実行されるため、停止する可能性が圧倒的に低くなる。

実際にこれが実証される出来事があった。2019年8月23日に発生した、AWS東京リージョンの障害のことである。AWSの報告によると⁵⁾、仮想サーバとそのストレージサービスを中心に、東京リージョン内の一部エリアが約8時間停止した。これによって、オンラインゲームやコード決済サービスなど、多くの企業のサービスが停止したと言われている。一方、KYB-IoTプラットフォームは一切停止することなく正常稼働を続け、高可用性であることが証明された。

但し、本プラットフォームでも条件によっては停止することは十分あり得る。パブリッククラウドを利用した場合でも、止まる前提でシステムを考え、いざ停止した時の対処方法の明確化などを事前に行うことは重要であり、必須である。

注10) 本当の意味でランダムであるかは、構成や利用するサービスの仕様による。

4.4.4 予知保全技術

開発した予知保全技術による故障判定の例を紹介する。昨今のAIブームは、AIという分野の中でもその性能の高さから深層学習が牽引している。しかしながら、一方では「ブラックボックス」、つまり説明性に欠けるという問題点が指摘されている。この点は徐々に改善されているものの、生産工程で利用する際には無視できないデメリットである。そこで、同じ設備に対してより説明性の高い従来型の機械学習^{注11)}のアプローチと、深層学習の大きく2パ

ターンにて開発を行い比較することにした。なお、いずれの場合も正常時のデータのみからAIを学習し、故障を判定する方策をとった。

ある設備の故障事例に対して、開発した予知保全技術で判定した結果を方策別にそれぞれ図9～11に示す。図9は、保全担当者と開発者の知見を盛り込んだ従来型の機械学習で判定した結果、図10は深層学習の中でもCNN^{注12)}を利用した結果、図11はRNN^{注13)}を利用した結果である。いずれも横軸が日付でおよそ5ヶ月分のデータを表示しており、縦軸がAIで出力した故障の危険度を表している^{注14)}。また、1本目の赤破線が故障時、2本目の赤破線が主要部品の定期交換時を示している。

図の通り、いずれのAIモデルにおいても、AIモデルが出力した故障危険度に対して最終的に図のような閾値を設定すれば、故障発生の1ヶ月程度前には予知できると言える。但し、この故障に関しては図9の従来型の機械学習を用いた結果が、最も良い結果となった。故障時期に近づくにつれて急激に故障危険度が上昇し、故障直後に行った暫定対策後もある程度高い故障危険度を維持している。そして、定期的な部品交換後は一気に安定へと向かっている。図10や11の深層学習の手法に関しても同様の傾向は見られるが、図9ほど顕著ではない。

一方、従来型の機械学習のデメリットとしては、保全担当者と開発者の知見を盛り込んでいるため、汎用性に欠けるといえる点が挙げられる。そのため、対象の設備が変わる度に一から検討が必要であり、展開スピードが遅くなる可能性がある。

このように、世間では深層学習が注目されているものの、従来型の機械学習が有効な場面はある。そして、そもそもAIを使わずに計測データに対して閾値判定するなど、より簡単な手法で対応できるのであれば、それがもっとも良い選択である。よって、引き続き技術革新を進めるものの、AIの活用といった手段が目的とならぬよう、多くの視点での検討が必要である。

注11) サポートベクターマシンなど、近年の深層学習の躍進の前の世代の機械学習のことを、本報では「従来型」と呼ぶ。

注12) Convolutional Neural Networkのこと。主に画像データに対して利用される。

注13) Recurrent Neural Networkのこと。主に時系列データに対して利用される。

注14) 各軸の具体的な数値は非公開としている。




図9 従来型の機械学習による予知保全結果




図10 深層学習 (CNN) による予知保全結果




図11 深層学習 (RNN) による予知保全結果

5 人財育成の取り組み

あらゆる産業において、AI人財を中心としたDX人財が求められており、人財不足は世界中で深刻化している。日本におけるこの原因の一つは人口減少であるが、それ以外にも日本特有の問題として、ベンダ企業へのIT人財集中化が挙げられる。IT大国である米国とは真逆で、日本ではIT人財の7割以上がベンダ企業に属している。このような状況により、日本のユーザ企業では、ITシステム開発をベンダにアウトソースする比率が極端に多くなり、結果として社内にノウハウや技術力が残らないといった問題が発生しやすい。その結果、昨今の世の中の急激な変化に対して、ユーザ企業が迅速な判断や対応ができない状況が発生している。そのため、近年は多くのユーザ企業において、DX人財の獲得や人財育成を進めている。

本章では、著者が関わった当社における近年のDX人財育成の取り組みと、DX専門組織設立に関し

て紹介する。

5.1 データマイニング活動

2016年から全社横断組織として、データマイニング^{注15)}の活用を推進するプロジェクト活動を行った。本活動では社内外の講師を迎え、若手を中心に統計やAIなどの基本技術習得のための人財育成を進めた。当社ではデータを活用する文化が十分に備わっているとは言えない状況であったため、本活動ではディープラーニングなどの最先端技術ではなく、まずは統計技術を中心に学び、実践をした。

その結果、いくつかの改善事例⁶⁾が生まれ、一定の成果が得られた。現在は、本活動は終了となっており、育成した人財が各事業にて各々データマイニングを進めている。

注15) 大量のデータに対し統計学やAIなどデータ解析技術を適用することで、潜在的な傾向や方向性などの有用な知見を獲得する技術のこと。

5.2 AI人財育成活動

データマイニング活動に続き、2018年からはディープラーニングなどの最先端のAI技術を有した技術者を育成する、AI人財育成活動を進めている。

具体的な活動内容としては、図12に示すように理論などを学ぶ講義の他に、Python^{注16)}を用いて実践的に学べるeラーニング、知識確認のための小テスト、グループディスカッションによってデータ分析を進める集合研修、参加者内のデータ分析コンペティションなどを実施している。また、小テストなどの技術解説だけでなく、実際の業務における課題や悩みごとの共有、AI以外にもPythonを用いた業務効率化の紹介やコード共有などを定期会合や社内チャットツールを通して進めている。

本活動は、従来型の講師と生徒のような縦の関係ではなく、年齢や入社年度など関係なく双方向のコミュニケーションがとりやすい仕組みとなるように考慮した。その結果、チャットツールなどのオープンな場でのやり取りやコード共有も活発化し、良い文化を築くことができつつある。

今後は、より多くのスキルレベルに合わせた研修プログラムを整備し、過去にAI人財育成活動に参加した人財が、次の人財を育てていくという流れをつくり、より広範囲の人財育成を推進していきたい。

注16) 汎用プログラミング言語の一つ。AIの開発におけるデファクトスタンダードの言語となっている。

5.3 DX専門組織の設立

前記活動を通してDX人財育成を進めてきたが、以下のような課題があった。

- ①人財の一部は本業との兼務になるなど、本活動を通して得られた能力が十分に活かせない

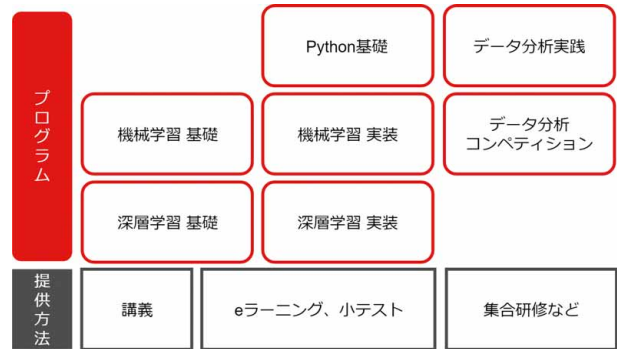


図12 AI人財育成プログラム

- ②AIを実際のプロダクションとして運用する際には、理論や実装能力以外に、開発環境の整備や学習用データおよびハイパーパラメータ^{注17)}の管理が必要であるが、個別に実施するのは非効率

- ③部署間での最新技術やコード共有などの、情報共有が不十分

そこで、AI, IoT, クラウドといった近年のデジタル技術を用いて、革新的モノづくりの実現やビジネスモデルの変革を実現するべく、全社横断的に活動するDX推進部を2019年8月に発足した。本組織は本報で紹介している生産技術領域だけでなく、製品や設計の領域を専門とする人財も有していることが特徴的である。

実施業務としては、各事業との共同による開発やコンサルティングのほか、4.4で紹介したKYB-IoTプラットフォームの機能拡充を実施する。特にKYB-IoTプラットフォームは、データ収集の仕組みや開発環境の提供、学習データなどの管理に至るまで全社標準として提供することによって、前記課題②を解決していく。また、直近の案件にとらわれることなく、主体的に新しい技術開発を進め、社内への最新技術情報発信を進めることにより、企業文化や風土の変革も目指す。さらに、DX人財育成プログラム提供や事業部からの社内インターンシップなど、継続的な人財育成も重要なミッションとして取り組んでいる。

現在は、IT人財が中心となっているが、今後はFA(Factory Automation)^{注18)}領域やハードウェアに強い人財も集め、DX推進部のみで迅速にPoC^{注19)}実施などができるような体制を整えていく計画である。

注17) アルゴリズムによって自動的に学習されないパラメータのこと。開発者が経験や別の最適手法を用いて決定するのが一般的である。

注18) 生産工程の自動化を図るシステムのこと。

注19) Proof of Concept(概念実証)の略で、コンセプト(概念)の実現可能性を検証することを指す。

6 今後の展望

今後もDX推進部を中心に製品、生産の両面でデジタル技術を活用し、全社横断組織として社内にデジタル技術を浸透させていく計画である。

また同時に、取り組む分野や視点も広げていきたい。本報で紹介した内容は、いずれも設備や製品に関するデータを活用した事例であったが、現在は人間の情報を取得することによって、人間を支援するようなシステム開発も進めており、今後はモノ・人の両面に注力していきたいと考えている。加えて、製品や設計領域から生産領域まで広く把握できるという部署の特徴を活かし、今まで活用が不十分であった設計×生産の切り口で、全体最適化を進めていく。

さらに、KYB-IoTプラットフォームの構築を重点取り組み事項として位置づけし、常に刷新をし続ける計画である。これによって、各部門がデータの運用管理や分析環境の構築などを意識することなくBIツール^{注20)}やAIを利用できるようにし、データドリブな企業文化を築き上げていきたい。

注20) Business Intelligence (ビジネスインテリジェンス) ツールの略。企業内の蓄積された大量のデータを集めて分析し、KPIなどを表示(可視化)させ、迅速な意思決定を助けるためのツールのことである。

7 おわりに

本報では、生産技術領域に特化したAI×IoT活用の取り組み事例の一部を紹介したが、これらのデジタル技術の活用は目的ではなく手段の一つである。今後もそのことを常に意識しながら、正しい活用を続けていきたい。

最後に、本報で紹介したシステム開発・導入、人材育成にあたり多大なるご支援、ご協力をいただいた関係部署の方々に、この場をお借りして厚く御礼申し上げます。

参 考 文 献

- 1) 経済産業省情報技術利用促進課：IT人材需給に関する調査(概要)、(2019年4月)。
- 2) 山本：工程管理システムの構築、カヤバ技報第14号、(1997年4月)。
- 3) 西尾、田辺：検査支援システムの開発、KYB技報第42号、(2011年4月)。
- 4) 中西、工藤：ロッドパッキンの外観検査技術の開発、KYB技報第51号、(2015年10月)。
- 5) Amazon Web Services, Inc.：東京リージョン(AP-NORTHEAST-1)で発生したAmazon EC2とAmazon EBSの事象概要、<https://aws.amazon.com/jp/message/56489/>(参照 2019年11月7日)。
- 6) 高松：データマイニングの活用事例、KYB技報第56号、(2018年4月)。

著 者



内藤 孝昌

2007年入社。技術本部DX推進部。生産技術研究所を経て現職。AI×IoTを活用したシステム開発に従事。