

# AIによる電子部品実装機の予兆検知

清水 圭 加部 隆久

通信機器の量産工場である情報通信本庄工場では、日産1万台以上の端末製品を生産している。従来の生産機種は多品種少量の大型製品が中心であったが、通信機器の無線化とIoT市場の広がりにより、現在は少品種大量の小型製品が中心となっている。

大量生産に対応するため、生産ラインは24時間の勤務体制で稼働が必要であり、ライン停止時間をどう短くできるかが課題となっている。稼働時間内に生産ラインが停止するのは、ラインを構成する製造設備に対し、主に次のような事象が発生した時である。

- ・段取替え (生産機種を変えるための準備作業)
- ・予防保全 (定期的な保全)
- ・事後保全 (突発的な故障の修理)

これらの作業のうち、段取替えの少ない大量生産では、予防保全をどう最適化し、事後保全をどう少なくするかが、ライン停止時間を短くするためのポイントとなる。しかし、製造設備の高性能化が進み、予防保全には多くのメンテナンス時間が必要となっている。また、予防保全を行っていても生産中に製造設備内の部品故障が突発的に起きれば、事後保全が必要となる。そのため、製造設備の状態を把握し、最適なタイミングで予防保全を行う仕組みが求められる。

本稿では、OKIのソリューション事業として、株式会社FUJI (以下、FUJI) と共同で開発中である電子部品実装機の予兆検知について紹介する。

## 電子部品実装機の予兆検知必要性

通信機器生産の中で自動加工が中心の基板実装工程は、中間コンベアー (運搬装置) を含めると10台以上の製造設備を連結したライン構成となる (図1)。




図1 一般的な基板実装ラインの構成例

連結構成のラインはどれか1台でも設備が停止するとライン全体が停止してしまう。そして、連結する生産設備の台数が多いほど、また設備の構造が高度になるほど予防保全によるライン停止時間は長くなり、突発的な故障の事後保全でライン停止するリスクも高くなる。

基板実装ラインを構成する製造設備の中で、電子部品を高速かつ高精度でプリント配線板上に搭載する電子部品実装機 (図2) は、特に精密な機構を持つため、他の設備に比べ保全への負担が大きくライン稼働に与える影響が大きい。

そこで、基板実装ラインの停止時間を抑えるためには、電子部品実装機の生産中設備状態を把握し、最適なタイミングでの予防保全が必要となる。その解決策として、電子部品実装機の異常に対するAI (機械学習) を用いた予兆検知に取り組んでいる。

モジュール型高速多機能装着機

**NXT**  
Fuji Scalable Placement Platform

高い生産性と柔軟性を兼ね備えた  
スケーラブルプレースメントプラットフォーム




図2 FUJI製 電子部品実装機<sup>1)</sup>

## 電子部品実装機の問題点

電子部品実装機を構成する機構のうち、故障頻度が高いのはフィーダー、ノズル、ヘッドの3つである。これらの機構は、図3のような異常事象に対して適切な保全を実施

しないと故障の発生につながる事が分かっている。また、故障にまで至らなくても異常事象のまま稼働を続けると、搭載精度の低下によって実装不良が発生する。



機構	機能	主な異常事象
フィーダー	リール状にテーピングされた電子部品を自動供給する	・送り機構の動作異常による部品供給の位置ずれ ・部品テープの剥離不良 ・異物、塵埃混入による動作不良
ノズル	フィーダーから供給された電子部品を吸着する	・先端部の劣化や異物、塵埃混入による部品吸着不良
ヘッド	ヘッド吸着した電子部品を基板上へ運び、搭載する	・回転動作の不安定による部品搭載位置ずれ

図3 電子部品実装機の予兆検知で着目する機構

故障や実装不良につながる原因の予兆を検知するために、各機構の異常事象に対しFUJIと要因分析を実施した。そして、電子部品実装機から得られるログデータを常時収集し、要因パラメーターを機械学習で分析することで異常事象を予測した。これにより、致命的な故障が発生する前に、異常事象の予兆を検知できるシステムを構築した。

### データ収集の仕組み

現在、情報通信本庄工場稼働中の電子部品実装機では、次のようなログデータをクラウド上に収集している。

- ・各機構で行っている補正量
- ・オフセット量
- ・部品吸着の位置誤差
- ・部品残数など

収集したログデータを元に、異常値を判別し異常事象を予測するためのモデル（予兆モデル）を作成する。そして、作成した予兆モデルを製造稼働中に収集されるリアルタイムなログデータの解析に利用することで、電子部品実装機の致命的な故障が発生する前に、異常事象の予兆を検知する仕組みとなっている（図4）。




図4 クラウドでのログデータ収集

### 工場IoTを支える統計解析モデル

IoTにより製造設備から常時収集される膨大な量のログデータを活用するためには、データモデリングや予兆モデルの作成が必要となる。これらには統計解析手法が多く用いられ、次に示す大きく2つのモデルがある。

#### ① 頻度分布による異常検出モデル

連続的変数の分布を推定し、外れ値（異常値）を検出するモデル。当てはめる分布には平均値周辺に集積する正規分布や、最大値周辺に集積するガンベル分布がある。

#### ② 時系列による予兆モデル

時間間隔で発生する離散的な事象（エラー）を数える特定の離散確率変数分布を示すモデル。ポアソン過程、ワイブルハザード（Weibull Hazard）関数、指数分布などによる統計手法である。代表的な時系列モデルとしては、時間に対する劣化現象や寿命を統計的に記述するワイブルハザード関数がある（図5）。




図5 ワイブルハザード関数を用いたバスタブ曲線

これは、大きく3つの期間に分けて、時間の経過とともに発生するエラー事象を解析する手法である。

- ・初期故障期間：初期故障に起因する故障は、時間とともにそのエラー事象が減少する。
- ・偶発故障期間：偶発的な事故などに起因する故障は、時間によらず一定間隔で発生する。

- ・摩耗故障期間：寿命が近づくと、時間とともにそのエラー事象が増加する。

今回の取組みでは、エラー発生事象は異常検出モデル（外れ値検出）、エラー発生頻度の時系列変化は予兆モデル（ワイブルハザード関数）、それぞれのモデルを組み合わせている。

## 異常事象の予兆検知手法

開発した予兆検知手法の流れは、以下の通りである。

- ① 収集されたログデータから統計的に異常事象と関連するパラメーターを見つけるために、データを可視化し確認する。
- ② 可視化で見つけたパラメーター（部品吸着の位置誤差など）の分布モデルを決定し、そのモデルにおける外れ値を検出できるよう学習する。
- ③ 外れ値の発生頻度を予測するモデルを学習し、異常事象の予兆を検知する。

### (1) データの可視化

収集されたログデータは約2000万レコードと膨大なデータ量となる。その中から、対象とする故障に関連するパラメーターが何になるのかを見つけるために、部品別、フィーダー別、ノズル別及び日付別に可視化して特定する。その結果、部品吸着時の位置誤差を可視化すると、発生頻度分布が単峰性あるいは2峰性の整った山なりの形状となることが分かった（図6）。




図6 位置誤差のデータ可視化イメージ

### (2) 分布モデルの機械学習と外れ値の検出

可視化で得られた単峰性の山に着目すると、正規分布の形状に似ている。従来、製造設備の異常検知では正規分布をモデルとして用いることが一般的である。しかし、

位置誤差の発生頻度分布を詳細に分析すると、少し歪んだ分布になり、正規分布モデルが当てはめられないことが分かった（図7）。そこで、正規分布の形状に対し、歪度（わいど）、尖度（せんど）に関するパラメーターを持つジョーンソンSU分布を用いる。

収集されたログデータからジョーンソンSU分布の4つのパラメーターを機械学習させることで、位置誤差の発生頻度分布に合う分布モデルを得る（図8）。




図7 正規分布による当てはめ




図8 ジョーンソンSU分布による当てはめ

モデル化した分布とログデータから統計的な外れ値を検出することにより、設備状態の故障や異常を明らかにする。外れ値とみなす閾値は、統計的な品質管理手法<sup>2)</sup>で使われる2700ppm（正規分布での標準偏差3σに相当）を、ジョーンソンSU分布に当てはめ、上限値と下限値を設定した（図9）。

機械学習を使用することで、フィーダー1本ごとを含めた個々の設備に対して分布モデルを最適化できる。そのため、従来の固定値での閾値設定では行えなかった、各々の設備状態に即した外れ値検出が行える。




図9 ジョンソンSU分布モデルによる外れ値の検出

### (3) 異常事象の予兆検知

ログデータから得られる位置誤差のモデルからの外れ値発生頻度を、動作回数ごとにプロットする(図10)。エラー発生頻度の時系列変化はワイブルハザード関数に従う。ワイブルハザード関数のパラメーターを観測された位置誤差の外れ値発生頻度から学習させれば、未来の動作回数に対する外れ値の発生頻度を予測できる。

外れ値の発生頻度は、異常事象が起きる前に大きくなることが検証で分かっている。そのため、実際に異常事象に至る前兆の外れ値発生頻度を異常値判定値として設定しておけば、ワイブルハザード関数で予測される外れ値発生頻度を元に異常事象の予兆を検知できる。




図10 ワイブルハザード関数を用いた予兆検知

予兆を検知した段階で、フィーダー、ノズル、ヘッドの関係する機構に予防保全を行えば、故障や実装不良につながる異常事象を未然に防ぐことができる。

### 今後の展望

本システムを適用することで、電子部品実装機は最適なタイミングで適切な箇所のメンテナンスを実施できる。図11に、フィーダー1本ごとに予兆検知を導入した場合の保全時間のイメージを示す。各々のフィーダー状態を把握

しているため、一律な定期保全よりも長い保全間隔で設備稼働ができる。よって、従来に比べ保全回数が少なくなり、保全にかかる作業コストと部材コストを削減できる。また、フィーダー状態のばらつきが抑えられるため、実装品質の安定化も期待できる。

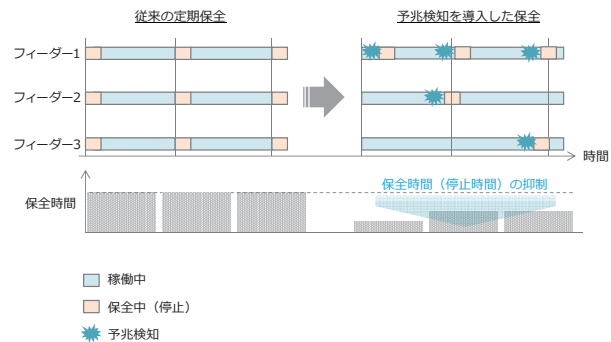


図11 予兆検知によるフィーダー保全の最適化

今後は、振動センサーを用いた部品故障の検出などを進め、FUJIとの更なる共創を元に予兆検知による保守最適化を目指していく(図12)。

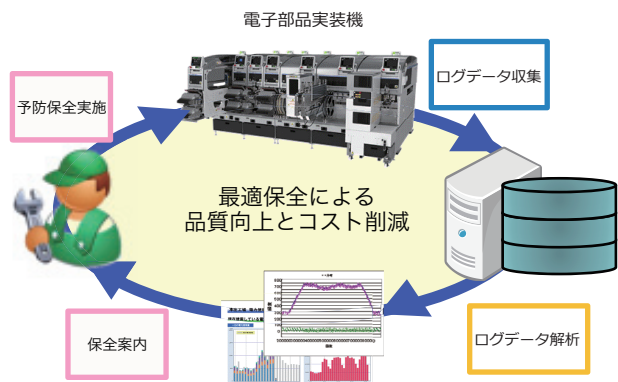


図12 予兆検知が目指す姿

### 参考文献

- 1) <http://smt.fuji.co.jp/products/mounter/>
- 2) ISO/TS 16949:2009品質マネジメントシステム—自動車生産及び関連サービス部品組織のISO 9001:2008適用に関する固有要求事項

### ● 筆者紹介

清水圭: Kei Shimizu. 情報通信事業本部 情報通信本庄工場 生産技術部  
加部隆久: Takahisa Kabe. 情報通信事業本部 IoTアプリケーション推進部