

IoT 技術を用いたプラント監視システムの研究

2022年 3月

平田 俊明

IoT 技術を用いたプラント監視システムの研究

平田 俊明

システム情報工学研究科

筑波大学

2022年 3月

概要

建物や工場の生産設備に設置されたさまざまな機械は、現代社会の重要な基盤を構成している。このような機械に異常が発生した場合、環境悪化や事業継続に大きな影響を及ぼす。このため、プラントの運転・監視については、古くから自動運転や故障検知を中心に実用化が進んでいる。しかし、運転の最適化や故障の早期検知、適切なメンテナンスなど、効率的な運用の実現は人手に依存している。さらに、現状はベテラン頼みの工場運営となっており、ベテランの退職、後継者不足に対応できておらず、製造業の現場力の維持・強化を図る上で人材の確保が最大の課題となっている。これに対し、定年延長などによるベテラン人材の活用でしのいでいるが、今後はIoT(Internet of Things)をはじめとするITやロボットなどのデジタル化に重点を移す動きが進展している。

近年、IoT(Internet of things) 関連技術の普及に伴い、これらの技術を用いたスマート工場への取り組みが進んでいる状況には、このような背景がある。本研究で対象とする飼料プラントの現場でも同様の課題を抱えており、最新のIoT機器を使用して工場の稼働状態を監視し、監視対象データを分析することで運用の最適化やタイムリーな機材のメンテナンスの実現が求められている。一方、IoTの活用に関しては、IoTデバイス、通信ネットワークの高性能化、低価格化が進展しており、利用しやすい環境が整ってきた。更にIoTデバイスを使って収集したデータの分析を自動化するための各種分析技術も利用できるようになってきた事もIoT技術の普及を後押ししている。このように、現場のデータ収集・活用への意識の高まりは見られるが、具体的な活用段階では、データの精度や正確性の担保、データの収集・整理が不十分、AI/IoTを導入する組織・人材の不足などの課題が多い。これらの一因として、IoTやデータ分析の技術を実際の工場に導入するための適切な選択過程が十分議論されていないことが挙げられる。

本研究は、この点に着目し、IoT技術やデータ分析を適切に利用するための留意点や開発プロセスを明らかにする。本研究のテーマであるプラント監視はプラントの安全性と生産性を維持するために重要である。監視方法および分析対象データは各プラントの特性に依存するため、必要な構成は監視対象のプラントによって異なる。例えば、本研究で対象とした飼料プラントの監視システムでは、単純な状態監視だけではなく機器の故障予知や定期交換部品の交換時期分析も必要とされていた。さらに監視システム全体の設計では、

各サブシステムに依存するさまざまなデータと分析方法を実装に必要な予算も含めて考慮する必要があった。また対象プラントは既存のプラントであり、監視システムを新たに設置するには、数十年を経過した古い機材が多数存在する中に、新しいIoTベースのシステムが既存の設備と連携できるようにシステムを構築する必要があった。本研究では、IoT機器やデータ分析技術を組み合わせ、実用的な工場の監視システムを実現するための留意点を議論する。先行研究では、単体の診断技術に焦点を当てているものが多く、また、主に新しいプラントの開発向けであり、既存のプラントの監視システムの構築には十分踏み込んでいない。本研究では、飼料工場のプラント監視システムの開発を通して、診断の前段階のデータ収集技術まで含めて検討し、それらを組合せ全体システムを設計する過程で注意すべき点を明確にし、プラント監視システムのより良い開発プロセスを提示する。

一方、データ収集技術に関しては、故障診断要求に基づくデータ収集速度／頻度などのデータ収集能力を実現するための諸課題、すなわち、(1) 遮蔽物や電磁波などの影響で電波環境の良くない工場内で安定的な通信をいかに確保するか、(2) コンピュータの運用に適さない環境でのセンサーやIoT-GW(IoT-Gateway)の選定と設置方法、(3) 全体システム構成を、コストも考慮しながら決定する必要があった。特に工場内では電波環境が悪く、安定的な通信の実現に注力する必要があった。先行研究では、IoTの利用形態ごとに必要なデータ通信容量や手段を提案しているが、実プラントにおけるノイズの評価と分析手法が要求するデータ収集性能など具体的な課題や定量評価を含めた対策までは踏み込んでいない。本研究では、上記課題をいかに解決したかを定量評価を含めて議論する。

更に、本研究では飼料工場を例として提案したプラント監視システムの開発プロセスを空調機設備にも適用した。空調機設備は社会基盤として重要であり、本研究では、データ収集および診断システムを導入するためのアプローチを提案する。空調機設備の運転・監視は、大規模施設を中心に集中監視が実現されている。一方、中小規模施設の空調機設備は、遠隔監視対象の設備は少なく、多くのケースで故障が発生してから対処している。本研究では、主として中小規模施設の空調機設備を対象とするが、これらは、ノイズの多い環境、コストの制約、および季節変化への対応などの課題がある。空調機の運転状態は、設定、気候条件、季節などの要因に大きく依存する。したがって、夏に作成した異常検知モデルは冬には使用できず、正確な異常検知を実現することは簡単ではない。一方、中小規模の施設用の空調機は、多くの分散施設に独立して設置されている。安価なIoTセンサー（コスト削減のために必要）の設置条件が悪いと、データにノイズが発生することが

あり、正確な診断を実現するには、IoT センサーを設置する場所も重要である。さらに、既存の分散した空調機を安価に監視するデータ収集システムの導入も課題である。

本研究では、(1) プラント監視システムの実現プロセスと AI 応用診断技術に関する研究、(2) プラント監視データ収集システムに関する研究、(3) プラント監視方式の空調機システムへの応用に関する研究、の 3 つの研究テーマについて述べる。

目次

第 1 章	序論	1
第 2 章	IoT 技術を用いたプラント監視システムに関する先行研究	5
2.1	研究分野の概況	5
2.2	先行研究の課題	10
2.3	本研究の目的	11
第 3 章	プラント監視システムの実現プロセスと AI 応用診断技術に関する研究	13
3.1	はじめに	13
3.2	飼料プラントのロール機監視システム	14
3.3	状態監視システム	16
3.4	故障予知システム	21
3.5	部品交換時期分析システム	27
3.6	データ収集システム	30
3.7	開発システムの特徴	33
3.8	開発プロセスと技術選択の留意点	34
3.9	むすび	35
第 4 章	プラント監視データ収集システムに関する研究	36
4.1	はじめに	36
4.2	データ収集システムの要件と構築上の課題	37
4.3	課題解決策	39
4.4	開発システムの特徴	51
4.5	むすび	52

第 5 章	プラント監視方式の空調機システムへの応用に関する研究	54
5.1	はじめに	54
5.2	空調機と IoT センサーの構成	54
5.3	異常検知システム	56
5.4	実験結果	60
5.5	むすび	72
第 6 章	総括と今後の研究展望	73
6.1	プラント監視システムの実現プロセスと AI 応用診断技術に関する研究	73
6.2	プラント監視データ収集システムに関する研究	75
6.3	プラント監視方式の空調機システムへの応用に関する研究	76
6.4	本研究の成果	77
6.5	今後の研究展望	81
謝辞		83
参考文献		84
関連業績リスト		92

目次

1.1	IoT の技術マップ	2
3.1	ロール機とセンサー設置位置	15
3.2	CNN のネットワーク構成	17
3.3	入力データの周波数特性 (上) と加速度値 (下)(従動系右側 X 軸)	19
3.4	運転パターンと消費電力量の関係	20
3.5	Autoencoder のネットワーク構成	21
3.6	疎構造学習	23
3.7	時系列データにおける k-近傍法	23
3.8	ベアリングで温度異常を検知	26
3.9	メインモータで振動異常を検知	27
3.10	ロール交換前後での疎構造学習異常度の推移	28
3.11	CNN によるロール交換前後の交換後判定比率の推移	29
3.12	データ収集システムの構成	30
4.1	監視対象機器とデータ収集システム	37
4.2	通信切断回数の推移	40
4.3	データ収集システムのデータ転送手順	42
4.4	Bluetooth 通信安定化の課題	43
4.5	リピーターによる通信の安定化	44
4.6	Bluetooth 通信再接続手順	45
4.7	Bluetooth 通信安定化後のデータロス率の推移	47
4.8	通信切断時間の分布	48
4.9	IoT-GW と PC 間の構成	49

4.10	IoT-GW と PC 間の通信手順	50
5.1	空調機とセンサー設置位置	55
5.2	データ収集システム	57
5.3	Convolutional Autoencoder の構成	59
5.4	学習データの追加数と外気温の推移の関係	61
5.5	第 2 回障害試験における室外機ファンモーターデータ解析結果	63
5.6	第 3 回障害試験における室外機ファンモーターデータ解析結果	64
5.7	第 2 回および第 3 回障害試験における温度推移	65
5.8	第 1 回障害試験における室外機ファンモーターデータ解析結果	66
5.9	単月データモデル (提案方式) による解析結果	69
5.10	複数月統合データモデルによる解析結果	70
5.11	ローコストタイプセンサーのデータロス数	71
5.12	ローコストタイプセンサーと通常タイプセンサーの異常度の推移	71
5.13	第 3 回障害試験におけるローコストタイプのセンサーを使用した室外機 ファンモーター解析結果	71

表目次

2.1	IoT 技術を用いた監視システムに関する研究分野	6
3.1	ランダムフォレストと CNN の精度比較	18
3.2	Autoencoder 中間層の次元数による loss 値の変化	22
3.3	異常検知結果	25
3.4	サンプリングレート、データ収集周期、センサー種別のデータ解析への影響評価	32
4.1	センサーと IoT-GW 間の通信方式	41
4.2	開発システムの要求事項と実現方式	52
5.1	データ収集条件	57
5.2	テスト項目とテスト条件	61
5.3	障害試験の結果	62
5.4	異常検知精度の比較 (8 月/12 月)	67
5.5	異常検知精度の比較 (12 月/1 月)	67
5.6	異常検知精度の比較	68
6.1	研究成果のシステム共通事項とシステム固有事項	78

第1章

序論

建物や工場の生産設備に設置されたさまざまな機械は、現代社会の重要な基盤を構成している。このような機械に異常が発生した場合、環境悪化や事業継続に大きな影響を及ぼす。また、プラント運転の自動化は、省力化による生産性の向上のため重要である。このため、プラントの運転・監視については、古くから自動運転や故障検知を中心に実用化が進んでいる [21] [22]。しかし、運転の最適化や故障の早期検知、適切なメンテナンスなど、効率的な運用の実現は人手に依存している。2017年版ものづくり白書(経済産業研究所) [1] では、製造業の現場力の維持・強化を図る上で人材の確保が最大の課題とされ、人材を課題とした5割以上の企業が技能人材の確保を課題としてあげている。このため、現在は、定年延長などによるベテラン人材の活用でしのいでいるが、今後はIoTをはじめとするITやロボットなどのデジタル化に重点を移すとしている [1]。近年、IoT(Internet of things) 関連技術の普及に伴い、これらの技術を用いたスマート工場への取り組みが進んでいる [1] [2] 状況にはこのような背景がある。一方では、プラント設備には数十年を経過した古いものも多く、デジタル化を難しくしている面もある。本研究の一部で対象とする飼料プラントの現場でも同様の課題を抱えており、現状はベテラン頼みの工場運営となっており、ベテランの退職、後継者不足に対応できていない。具体的には、最新のIoT機器を使用して工場の稼働状態を監視し、監視対象データを分析することで運用の最適化やタイムリーな機材のメンテナンスの実現が求められている。

一方、IoTの活用に関しては、IoTデバイス、通信ネットワークの高性能化、低価格化が進展しており、利用しやすい環境が整ってきた [6] [23] [24]。図 1.1 にIoTの技術マッ

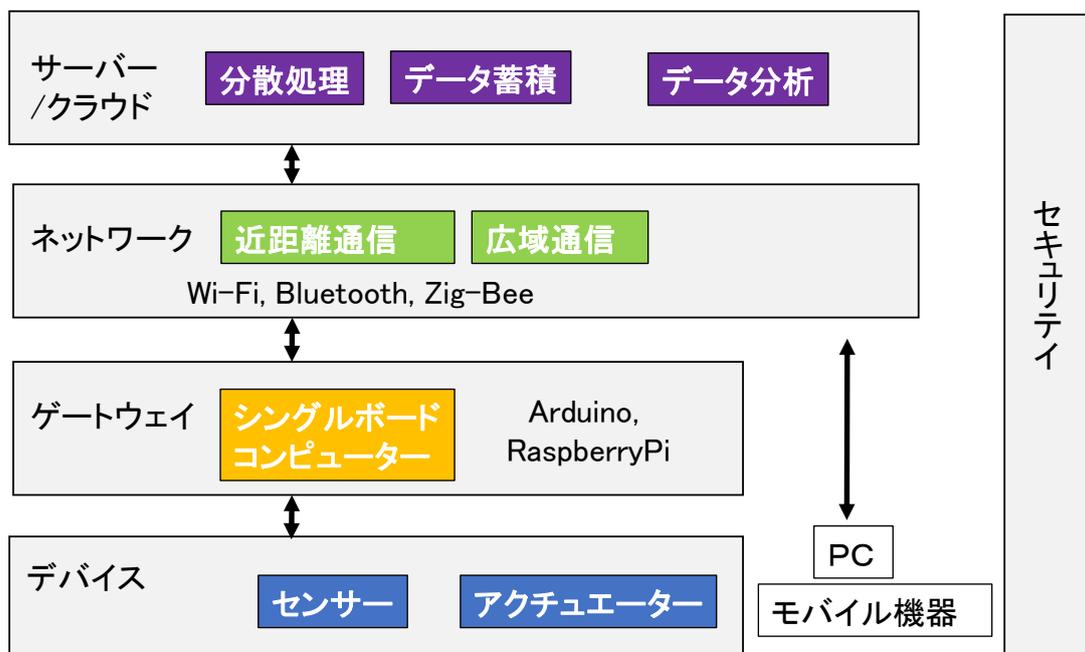


図 1.1 IoT の技術マップ

プを示す。Arduino や RaspberryPi^{*1}といったシングルボードコンピュータ、温湿度センサー、圧力センサー、流量センサーなどのデバイスとセンサーネットワークを構成する Bluetooth, Wi-Fi, Zig-Bee といった近距離無線通信、低コスト、低消費電力のデバイスを利用して数キロメートル以上のカバー範囲を持つ LPWA(Low Power Wide Area) ネットワーク [4] などの技術がある。更に IoT デバイスを使って収集したデータの分析を自動化するための各種分析技術も利用できるようになってきた事も IoT 技術の普及を後押ししている。

一方、2017 年版ものづくり白書 [1] では、現場のデータ収集・活用への意識の高まりは見られるが、具体的な活用に至っては至っていない状況が見て取れる。この状況は、2021 年度版ものづくり白書 (経済産業省) [2] から現在でもデジタル化推進の課題となっている。また、平成 30 年度版情報通信白書 (総務省) [3] では、IoT 導入の課題として、データの精度や正確性の担保、データの収集・整理が不十分、AI/IoT を導入する組織・人材の不足が挙げられている。このような状況の一因として、IoT やデータ分析の技術を実際の工場に導入するための適切な選択過程が十分議論されていないことが挙げられる。

本研究は、この点に着目し、IoT 技術やデータ分析を故障の早期検知などに適切に利用

^{*1} これらは実験機で使われることが多く、プラント等の実環境では耐久性、信頼性を確保した産業用途のマイクロコンピュータシステムが利用される

するための留意点や開発プロセスを明らかにする。本研究のテーマの1つであるプラント監視はプラントの安全性と生産性を維持するために重要である。監視および分析されるデータは各プラントの特性に依存するため、必要な構成は監視対象のプラントによって異なる。本研究で対象とした飼料プラントの監視システムでは、単純な状態監視だけではなく機器の故障予知や定期交換部品の交換時期分析も必要とされていた。さらに監視システム全体の設計では、各サブシステムに依存するさまざまなデータと分析方法を実装に必要な予算も含めて考慮する必要がある。また対象プラントは既存のプラントであり、監視システムを新たに設置するには、数十年を経過した古い機材が多数存在する中に、新しいIoT ベースのシステムが既存の設備と連携できるようにシステムを構築する必要がある。3章、4章では、IoT 機器やデータ分析技術を組み合わせ、実用的な工場の監視システムを実現するための留意点を議論する。先行研究では、単体の診断技術に焦点を当てているものが多いが、本研究では、飼料工場のプラント監視システムの開発を通して、診断の前段階のデータ収集技術まで含めて検討し、それらを組合せ全体システムを設計する過程で注意すべき点を明確にし、プラント監視システムのより良い開発プロセスを提示する。

データ収集技術に関しては、故障診断要求に基づくデータ収集速度／頻度などのデータ収集能力を実現するための諸課題、すなわち、(1) 遮蔽物や電磁波などの影響で電波環境の良くない工場内で安定的な通信をいかに確保するか、(2) コンピュータの運用に適さない環境でのセンサーやIoT-GW(IoT-Gateway) の選定と設置方法、(3) 全体システム構成を、コストも考慮しながら決定する必要がある。特に工場内では電波環境が悪く、安定的な通信の実現に注力する必要がある。先行研究では、IoT の利用形態ごとに必要なデータ通信容量や手段を提案しているが、実プラントにおけるノイズの評価と分析手法が要求するデータ収集性能など具体的な課題や定量評価を含めた対策までは踏み込んでいない。本研究では、上記課題をいかに解決したかを定量評価を含めて議論する。

更に、5章では飼料工場を例として提案したプラント監視システムの開発プロセスを空調機設備にも適用した。空調機設備は社会基盤として重要であり、5章では、データ収集および診断システムを導入するためのアプローチを検証し、3章、4章で提案した手法の一般性を確認する。

空調機設備の運転・監視は、大規模施設を中心に集中監視が実現されている[89][90][91][92]。また、中小規模施設の空調機設備は、遠隔監視対象の設備は少なく、多くのケースで故障が発生してから対処している。5章では、主として中小規模施設の空調

機設備を対象とするが、これらは、ノイズの多い環境、コストの制約、および季節変化への対応などの課題がある。空調機の運転状態は、設定、気候条件、季節などの要因に大きく依存する。したがって、夏に作成した診断モデルは冬には使用できず、正確な異常診断を実現することは簡単ではない。一方、中小規模の施設用の空調機は、多くの分散施設に独立して設置されている。安価な IoT センサー（コスト削減のために必要）の設置条件が悪いと、データにノイズが発生することがあり、正確な診断を実現するには、IoT センサーを設置する場所も重要である。さらに、既存の分散した空調機を安価に監視するデータ収集システムの導入も課題である。飼料工場を例とした開発プロセスでは、実用的なプラント監視システムを実現するプロセスと留意すべき側面を示した。空調機設備に関しては、前記プロセスに従ってデータ収集システムと診断方法を検討し、特に空調機固有の診断モデルを季節的に調整することにより、空調機の異常検知システムを実現する。

本論文の構成は次の通りである。2章で先行研究を概観した後、3章でプラント監視システムの実現プロセスに関する研究、4章でプラント監視データ収集システムに関する研究、5章でプラント監視方式の空調機システムへの応用に関する研究、6章で総括と今後の展望をそれぞれ述べる。

第 2 章

IoT 技術を用いたプラント監視システムに関する先行研究

2.1 研究分野の概況

プラント監視システムに関する研究の全体像を表 2.1 に示す。表 2.1 に示すように要素技術に関する研究分野と実システムへの応用に関する研究の各分野がある。要素技術に関する研究は、センサーやマイクロコンピュータ、通信ネットワーク、セキュリティなどの IoT の要素技術に関する研究と異常検知を中心としたデータ分析に関する研究分野がある。一方、実システムへの応用に関する研究では、各種プラント監視に関する研究開発のほか、異常検知などのデータ分析に焦点をあてた研究とネットワークやセキュリティなどのデータ収集に焦点をあてた研究がある。本研究では、データ分析や IoT の要素技術に関する研究成果や実用化済みの技術を利用し監視システムを構築する。すなわち、実システムへの応用に関する研究が、本研究の対象分野であり、前記要素技術を実際のプラントに導入するための適切な技術選択のプロセスと留意点を明らかにし、具体的なシステム構築上の課題と解決策を提案することが本研究の目的である。各研究分野の概況を以下に示す。

2.1.1 IoT 技術概況

IoT 技術全般 (表 2.1 研究分野#1):

境野 [5] および清尾 [6] [7]、辻井ら [9] では、センサー、マイクロコンピューター、ネットワーク、クラウド、プロトタイプ開発、信頼性、セキュリティなど様々な観

表 2.1 IoT 技術を用いた監視システムに関する研究分野

#	研究分野	代表研究	
1	IoT 技術概況	全般	境野 [5], 清尾 [6] [7]
2	IoT 要素技術に関する研究	センサー, コンピュータ (IoT-GW)	Xue [27], Loghin [28], 高尾 [30] Fukae [33]
3		通信ネットワーク, セキュリティ	服部 [54], Kubo [56], Jiang [57], 宇谷 [55], Shahina [61], Abbas [73], Chze [74]
4	データ分析 (異常検知手法) に関する研究	教師なし学習/教師あり学習	Hinton [46], Alqahtani [93], 井手 [35], Tony [94], Gornitz [37], Shilton [38], Jumutc [39]
5	実システムへの応用に関する研究	データ分析 (異常検知)	近藤 [10], 貝戸 [11], 野村 [12], 緒方 [13], 小野田 [14], Ito [80], Harada [82], Shi [84]
6		データ収集 (通信ネットワーク, セキュリティ)	Bhuvaneswari[63], 相原 [64], 松井 [65], 繁田 [66], 森部 [69], 鈴木 [70], Ulusar[67], Zhong[68]
7		プラント監視システム	今井 [18], 高須 [19], Krishna[16], Marcu[17], 馬場 [92], 山本 [89], 蜷川 [90], Song [87], Jiang [88]

点から IoT の技術要素とこれらを用いたシステム構築方法および事例を紹介している。また、IoT の技術要素は、瀬戸ら [23] や稲田ら [24] の著書に应用事例を含めて紹介している。池邊 [25] では、通信技術の観点から標準化技術を中心に紹介している。大江ら [8] では、IoT システム構築に際して、コンポーネントを選択する方法、フレームワークを使用して構築する方法などプロトタイピング方法について紹介している。

2.1.2 IoT 技術要素に関する研究

センサー, コンピュータ (IoT-GW)(表 2.1 研究分野#2):

コンピュータ (IoT-GW) 関連では、エッジコンピュータに関する研究が多い。Xue et al. [27] では、エッジコンピュータを概説し有効なアプリケーション例を示している。Loghin et al. [28] では、エッジ、クラウド、エッジとクラウドのハイブリッドの 3つの形態の性能比較を実施、高尾ら [30] では、エッジコンピューティングに

において誤差量を理論的に保証するデータ集約処理を提案している。Kono et al. [29]では、エッジコンピューティングに適した MPU アーキテクチャを提案している。一方、センサーデバイスに関しては、Fukae et al. [33]では、過酷な環境でのデータ計測として、養殖場において長期間水質を測定可能なセンサープラットフォームの開発事例を紹介している。

通信ネットワーク, セキュリティ (表 2.1 研究分野#3):

服部ら [54]では、大規模なセンサーネットワークにおけるロバスト性を確保したセンサーデータの収集方法を提案している。ネットワークトラフィックを削減する方式に関する研究として、Kubo et al. [56]では、トラフィックを削減するルーティング方式を提案、Jiang et al. [57]では、バックボーンネットワークの負荷低減を実現する IoT-GW の方式を提案している。省電力の観点からは、宇谷ら [55]では、森林などの大規模無線センサーネットワークにおける省電力ネットワーク制御方式を、Ko et al. [58]では、センサーデバイスのスリープモードのスケジューリングを制御することでエネルギー効率を高める方式を提案している。ワイヤレスセンサーネットワークにおいて、センサーデータの収集を効率化するため機械学習を利用する方法も提案されている [60] [61]。Shahina et al. [61]では、クラスタリングとデータ集約に機械学習を適用することでデータ量を削減、省電力につなげている。

一方、IoT セキュリティも重要な課題である [62]。Abbas et al. [73]では、デバイスを保護する 2 段階の方式を提案、Chze et al. [74]では、多層パラメータを利用してセキュリティを強化したマルチホップルーティング方式を提案、Majumdera et al. [75]では、デバイスの消費電力率を使用して攻撃の予測と検出を行う方式を提案している。また、Iellamo et al. [59]では、盗聴を防止するために人工的なノイズを付与する方式を提案している。

2.1.3 データ分析 (異常検知手法) に関する研究

異常検知手法に関する研究は幅広く行われている。井手 [34]の著書では、異常検知の基本的な手法を紹介している。異常検知の手法としては、正常運転時のデータを基準とした偏差から異常を検知するアプローチ (教師なし学習) と正常・異常のラベルの付いたデータから判定することにより精度を向上させるアプローチ (教師あり学習) がある。

教師なし学習 (表 2.1 研究分野#4):

教師なし学習では、代表的な方法として、Autoencoder [46]、Convolutional Autoencoder [93]、疎構造学習 [35]、k-近傍法 [34]、密度比推定法 [35]、Isolation Forest [94] がある。これらは、3章、5章で詳細を説明する。上記以外にも One Class SVM [51] や MT 法 [52] などの古典手法のほか、近年では、Chalapathy et al. [49] ではワンクラスニューラルネットワークによる手法を、Chen et al. [53] では GAN(Generative Adversarial networks) に基づく手法を提案している。

教師あり学習 (表 2.1 研究分野#4):

教師あり学習では、Gornitz et al. [37]、Shilton et al. [38]、Jumutc et al. [39]、がある。Gornitz et al. は、少ない教師データから高い精度を実現する方式を提案している。Shilton et al. は、多クラス分類と異常検出を1つのステップに組み合わせて、未知のデータの検出精度を向上させる SVM に基づく方式を提案、Jumutc et al. は検出精度向上と計算時間短縮の両方を実現する SVM に基づく方式を提案している。また、Riley et al. [48] では、教師ありニューラルネットワークを備えた Autoencoder 方式を提案している。

2.1.4 実システムへの応用に関する研究

データ分析 (異常検知)(表 2.1 研究分野#5):

異常検知に関しては、産業分野への応用に関する研究が多い。近藤 [10] のオクターブ帯域分析を使用した車両機器診断システムと1クラス分類を使用した異常検出事例、貝戸ら [11] の統計的検定に基づく変化点検出方法を使用した社会インフラ機器を維持するための異常検出事例、野村ら [12] の配管バルブの健全性監視に畳み込みニューラルネットワーク (CNN) を使用し流体圧力変動によって引き起こされるバブルの振動変化を特定した事例がある。また、緒方ら [13] では、フーリエ局所自己相関特徴による風力発電システムの異常検知方式を提案、小野田ら [14] では、水力発電システムの故障の兆候を検知するため、さまざまなセンサーデータや気象情報を用いて One Class SVM による分析事例を紹介している。Haque ら [15] では、ビル制御システムにおける侵入検知に Autoencoder と One class SVM を組み合わせて異常の見逃し率と検知率の両方を向上させた事例を報告している。機械装置の可

動部品の異常個所を診断する方法も古くから研究されており [31]、近年では機械学習を用いた精度向上の試みもある [32]。

産業分野以外でも異常検知技術は広く活用されており、Ito et al. [80] では、Online sequential extreme learning machine [81] と Autoencoder [46] の組み合わせを使用して、UNIX コマンドシーケンスの異常を検出する方法を提案、Harada et al. [82] では、局所外れ値因子 [83] を使用して水族館管理システムの異常検出を実現、Shi et al. [84] では、support vector machine [85] と deep belief network [86] を使用して、半教師あり学習でネットワーク侵入検知システムを実現した事例を報告している。

データ収集 (通信ネットワーク, セキュリティ)(表 2.1 研究分野#6):

IoT/CPS(Cyber Physical Systems) のデータ収集のための通信ネットワークに着目した研究として、Bhuvaneshwari et al.[63]、相原 [64]、松井 [65] がある。Bhuvaneshwari et al. は、IoT の応用分野と通信ネットワーク技術を概観している。相原は、インフラ維持管理の長期モニタリング、人や車の動きなどからその実態を捉える動態把握など具体的な適用例ごとに要求されるデータ収集量と通信容量、具体的な通信手段を提案している。松井は、IoT 基盤としての無線通信およびネットワーク技術の方式とスマートメータシステムや車車間通信/路車間通信など実用化に向けた取り組み例を紹介している。繁田ら [66] では、農業用センサーシステムの構築における通信ネットワークの課題と対応方針を示している。森部ら [69] では、圃場における無線ネットワークを地面や金属支柱、作物の揺れの影響など電波特性を把握したうえでシステムを構築した事例を紹介している。鈴木ら [70] では、自動運転などのリアルタイム性に着目して、LPWA, モバイルエッジコンピューティングなど IoT 活用上のクラウドネットワークの課題と課題解決を示している。Ulusar et al.[67] では、無線通信ネットワークにおける性能、ルーティング、等の諸課題とともに周波数帯や通信距離に基づくデータロスに関する研究を概観している。Zhong et al.[68] では、IoT-GW に着目した機能アーキテクチャとホテルチェーンを例にしたアプリケーション構成を提案している。

プラント監視システム (表 2.1 研究分野#7):

大規模システムを中心にプラント監視は広く実現されている。1 章でも述べたように、近年は、ベテラン作業員の退職や後継者不足によるノウハウを含めた自動化

ニーズが高まっており、IoT 技術を利用した開発事例が増えている。今井ら [18] では、上下水道プラントの運転パターンを抽出することにより配水パターンを分類し根拠を明確にした事例を、高須ら [19] では、発電プラントの運用で従来五感に頼っている巡回監視の効率化のため、運転員を多能工化するナビゲーションシステム及び AI を用いた画像・音響による現場監視システムの開発事例をそれぞれ紹介している。産業系以外への事例も増えており、農業分野では、Krishna et al.[16] では、植物プラントの監視システムで画像を用いた疾患の分析と特定を実現した事例を、Marcu et al.[17] では、植物をセンサーで監視し、葉の湿り具合、土壌と空気の湿度、空気と土壌の温度などの関係性を分析する事例をそれぞれ紹介している。

本研究で対象とした空調機設備に関しても大規模システムの集中監視を実現した事例が報告されている。馬場ら [92] では、大規模空調設備の予知保全サービスを紹介している。山本ら [89] では、空調機の空気温度設定の自動運用により省エネルギーを実現する遠隔監視システムを開発した事例を、蜷川ら [90] では、インターネット Web 連携通信による広域のビル空調設備の監視システムの開発事例を、菅ら [91] では、ビル用マルチの運転データを基に、機器の運転状況を分析する (用途別や月別の設定温度の運用とエネルギー消費量の比較など) ためのデータベース開発事例をそれぞれ紹介している。一方、研究レベルでは、Song et al. [87] や Jiang et al. [88] など、空調機の電力消費にフォーカスした手法研究がみられる。

以降、先行研究の残された課題を整理し、本研究の目的を述べる。

2.2 先行研究の課題

先行研究の課題を以下に示す。

- 表 2.1 研究分野#1、#7 に示すように、発電プラント、植物プラント、大規模空調設備監視システムなど産業分野での実システムへの応用に関する研究開発事例は多い。しかし、IoT 機器やデータ分析技術を組み合わせ、実用的な工場の監視システムを実現するためのプロセスと留意点が必ずしも明確になっていない。
- 前記表 2.1 研究分野#1、#7 に示す先行研究の事例は、主に新しいプラントの開発向けであり、既存のプラントの監視システムの構築には十分踏み込んでいない。

- 異常検知手法は、表 2.1 研究分野#4、#5 に示すように多くの手法が考案されている。しかし、これらは監視対象に設置したセンサーから収集した時系列データを分析することで異常検知を実現したもので、主に単一ソースデータの分析に使用される新しい診断方法の開発に重点が置かれており、解析に必要なデータ量やデータの収集方法に関する議論には踏み込んでいない。
- 前記表 2.1 研究分野#4、#5 では、正確なデータが利用可能であるとの仮定が置かれているケースが多く、5章で述べる低コストセンサーの使用によって引き起こされるノイズの影響などは十分に考慮されていない。
- データ収集に関する研究は、表 2.1 研究分野#6 に示すように、適用例ごとに要求されるデータ収集量と通信容量、具体的な通信手段を提案したり、無線通信におけるデータロスへの取り組みがある。これらは、データ収集に関する機能・仕様の検討が中心で、ノイズ対策などシステム導入時に直面した具体的な課題や定量的な評価を含めた対策まで踏み込んでいない。

2.3 本研究の目的

本研究では、従来研究の範囲で不十分な以下の課題を解決し、データ収集から分析までの全体システムを設計する過程で注意すべき点を明確にして、プラント監視システムのより良い開発プロセスを提示することを目的とする。3章でプラント監視システムの開発プロセスを提案した。提案した開発プロセスに基づき、3章、4章では飼料工場における監視システム、5章では空調機システムの故障診断の各実証実験を通して諸課題をいかに解決したかを示す。

- プラント監視システムの実現プロセス
プラント監視システムの開発において、IoT 機器やデータ分析技術を組み合わせ、実用的な工場の監視システムを実現するための留意点を明確にした適切な開発プロセスを飼料工場の監視システムを例に3章で議論する。また、提案した開発プロセスを空調機システムの故障診断に適用した例を5章で議論する。
- 既存プラントでの監視システム構築
既存のプラントの運用に影響を与えることなく外付けで監視システムを構築するた

め、センサーや IoT 機器の選定と設置、ケーブルの敷設等のシステム構築上の諸課題と解決策を飼料工場の監視システムを例に 3 章、4 章で議論する。システム構築では、必要な予算も考慮する。

- 目的に応じたデータ分析の精度向上

運転パターンの変化など機器固有の故障診断や最適な部品交換時期分析のためのデータ分析精度の向上のための方式を飼料工場の監視システムを例に 3 章で、空調機システムの故障診断を例に 5 章で議論する。

- データ分析に必要十分なデータ量/データ収集方法

導入コストを考慮し、データ分析に必要十分なデータ量やデータの収集方法をセンサーの選択を含めて明確化のため、飼料工場の監視システムを例に、データ量に関する解決策を 3 章で、データ収集方法に関する解決策を 4 章でそれぞれ議論する。また、空調機システムの故障診断を例にデータ収集の安定性の低いローコストタイプの振動センサーを用いて評価する。

- 現実に直面した課題解決・評価

通信の安定性などのシステム導入時に直面した具体的な課題解決やシステムの安定的な運用を担保するため、性能や信頼性など定量的な評価を含めた対策方法を飼料工場の監視システムを例に 4 章で議論する。

第3章

プラント監視システムの実現プロセスと AI 応用診断技術に関する研究

3.1 はじめに

本章では、IoT 機器やデータ分析技術を組み合わせ、実用的な工場の監視システムを実現するための留意点を議論する。従来の関連研究では、単体の診断技術に焦点を当てているものが多いが、本研究では、診断の前段階のデータ収集技術まで含めて検討し、それらを組合せ全体システムを設計する過程で注意すべき点を明確にし、プラント監視システムのより良い開発プロセスを提示する。具体的には、機器の故障の検出と交換部品の適切な交換時期分析を目的とした監視システムを実現する。

プラント監視システムは、表 2.1 研究分野#1,#7 に示すように幅広く研究開発が行われている。しかし、紹介された事例は主に新しいプラントの開発向けであり、既存のプラントの監視システムの構築には十分踏み込んでいない。異常検出方法も表 2.1 研究分野#4 に示すように多くの手法が考案されている。また、異常検知に関する実際の適用事例も表 2.1 研究分野#5 のように多くの試みがある。これらの研究は、監視対象に設置されたセンサーから収集された時系列データを分析することで異常検出を実現したもので、主に単一ソースデータの分析に使用される新しい診断方法の開発に重点が置かれ、解析に必要な十分なデータ量やデータの収集方法に関する議論には踏み込んでいない。本研究では、単一センサーのデータを監視するための適切な方法の選択に加えて、複数のセンサーデータと手法を経済的に組合せて利用する方法を検討した。特に、本研究では、サンプリングレートと収集周期を考慮し適切な解析結果を得るためのデータ量とデータ収集方法の検討

を含めた。異常検知手法としては表 2.1 研究分野#4 に示すように多くの技術が存在するが、全てを網羅する事は研究の目標とせず、実現可能な技術を如何に組合せ実用的なシステムを構築したかの過程を議論する。なお、異常検知の手法としては、表 2.1 研究分野#4 に示すように、正常運転時のデータを基準とした偏差から異常を検知する方法と正常・異常のラベルの付いたデータから判定する教師あり学習により精度を向上させるアプローチがあるが、本研究では、異常データの採取が困難なことから正常状態からの偏差を検出する手法を採用した。具体的には飼料プラントの監視システム構築を例に、分散設置した工場内の機械装置からプラント監視を実現するために必要十分なデータを収集し、適切な解析結果を得るための留意点として、(1) 監視データの選択、(2) 実験室での小規模実験、(3) データ収集速度、(4) システムの全体設計を報告し、さらに、実証実験システムの構築を通して、これらの課題をいかに解決したかを示す。

3.2 飼料プラントのロール機監視システム

図 3.1 に本研究で対象とする飼料プラントのロール機とセンサー設置個所を示す。ロール機は原材料を粉砕し所望の粒度の粉体を生成する装置である。ロール機では、メインモータの動力が、主ロール駆動側に伝えられ、これが主ロール従動側に伝えられる。機械装置では、駆動部が故障を生じやすく、また、故障による生産プラントへの影響が大きい。

この駆動部を監視する箇所として、主ロールのベアリング4か所とメインモータを選定した。監視箇所の振動データを主たる情報とし、電力量と温度データも解析の信憑性を高めるための補足情報として利用した。これらの情報はロール機に設置した各センサーから取得した。振動データの収集は、振動情報の精度を確保するため3軸加速度センサー(X軸、Y軸、Z軸を採用;Z軸が垂直方向)を利用し、各センサーともデータ解析時の比較容易性を考慮し、各軸の方向をそろえて設置した。

実稼働中のプラント環境はIoTシステム構築上様々な課題が存在する。IoT-GWと監視対象センサーとの距離は数メートル程度である。電磁波、様々な障害物、限られた空間がIoT-GWとセンサー間の通信の障害になりうる。また、既存の機械装置の構造は、IoT機器の設置を考慮していないため、設置上の課題もある。実システム開発には予算上の考慮も必要である。

以降、本研究で開発した監視システムの、状態監視、故障予知、部品交換時期分析、デー

タ収集の各機能について詳述する。

3.3 状態監視システム

本研究で対象とする機械装置の稼働状態は、原材料の種類、混合状態、投入速度などに依存して変化する。従来ベテランの運転員は電力使用量の変化から稼働状態を把握していたが、今回の開発にあたって、振動データも使った状態把握を試みた。ここで、原材料の混合状態等はかならずしも一定ではなく、混合状態からくる負荷の変化により稼働状態も細かく変動するが、その稼働状態を可視化することは安定運用にとって重要である。

開発の始めに、経験の不足した新しいオペレーターでもプラントの状態を理解できるようにするため、粉碎中の負荷に応じた 6 秒～7 秒の振動データに基づくステータス監視用のラベル付け機能を開発した。振動データに着目することで、後述の故障予知システム実現につなげた。この開発では振動データを多クラス分類手法によって解析した。稼働状態は、振動パターンと消費電力量に現れ、振動パターンは消費電力量と相関がある。システムでは振動データを用いて材料粉碎中の負荷に応じた 3 運転パターンと空運転の計 4 パターンへの分類を試みた。具体的には、粉碎中の負荷は電力量にも現れるため、カテゴリ 0:空運転 (2.5kwh)(原材料未投入)、カテゴリ 1:消費電力量 2.5～8kwh(低負荷原材料粉碎中)、カテゴリ 2:消費電力量 8～12kwh(中負荷原材料粉碎中)、カテゴリ 3:消費電力量 12kwh 以上 (高負荷原材料粉碎中)、の 4 カテゴリが振動データを用いて把握できる事を確認した。分類手法は CNN [40] [41] とランダムフォレスト (RF) [42] を用いた。CNN および RF の入力として、3 軸の加速度値を振動データの特徴抽出に有効な高速フーリエ変換 (FFT) 処理した 324 点のスペクトル強度を用いた。出力は前述のカテゴリ分類 (0,1,2,3) である。CNN のネットワーク構成を図 3.2 に示す。3.6 節で示すようにセンサーの性能を考慮し 50Hz のサンプリング周期でデータを収集した。1 つの観測データ長を約 6 秒～7 秒 (振動パターンの変化を認識できる想定最長値) とし、CNN の処理に適した 324 点を採用し、18x18 次元にリサイズして CNN の入力とした。

図 3.3(上) に例示する FFT データ (従動系右側 X 軸) は、図 3.3(下) の加速度データ (従動系右側 X 軸、20msec ごと 324 点) から生成したものである。^{*1} 図 3.3(上) では、駆動に

^{*1} 図 3.3(上) は、図 3.3(下) から生成した FFT データそのものであり 162Hz を境に鏡像となっている。縦軸は FFT で出力したスペクトル強度 (単位なし) である。このため、40Hz 付近のピークは 280Hz 付近にも表れている。後半側 (162Hz-324Hz) は鏡像であるが計算結果には影響ないため 324 点全体のデータを入

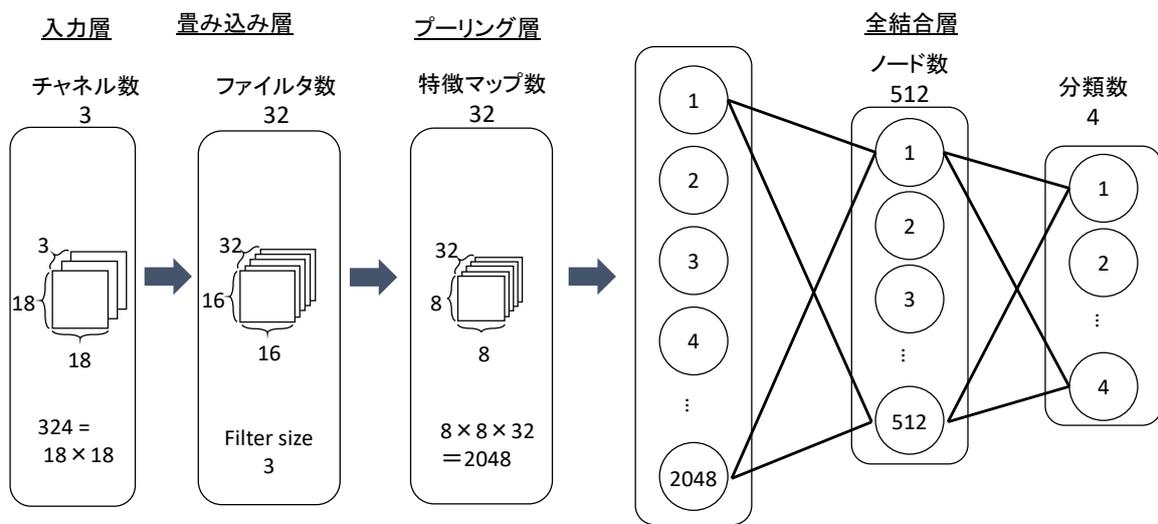


図 3.2 CNN のネットワーク構成

表 3.1 ランダムフォレストと CNN の精度比較

Sensor position	Random forest (%)	CNN (%)
MAINBRG LB	78.25	76.45
MAINBRG LF	69.88	78.59
MAINBRG RB	86.30	86.69
MAINBRG RF	81.29	82.11
MAINMTR	78.58	83.01

伴うスペクトル強度のピーク (スペクトル強度 100 を大きく超えている 40Hz 付近) を周波数特性の特徴点として捉えている。また、ピーク周波数は前述の稼働状態 (粉碎中の負荷に応じた 6 秒 ~7 秒の振動パターン) により 30Hz~50Hz の範囲で変化するが、観測周波数帯域 (1Hz-162Hz) に対しても十分余裕があることも分かる。^{*2}図 3.3 は X 軸のみを表示したが、Y 軸、Z 軸も同様の傾向にある。また、CNN の構成は filter サイズよりも filter 数のほうが精度に影響することから [43]、filter サイズは小さめの 3 とし、filter 数を 32 と大きめに設定した (図 3.2)。

実運用に入る前に、3 か月間収集した振動データからロール機の稼働状態を 3 つの運転パターン (原材料の粉碎中の状態) と空運転状態に分類できることを確認した。具体的には図 3.4 の黒の点はロール機の稼働状態の分類結果を示し (縦軸左)、原材料の粉碎に必要な消費電力量から判断される稼働状態 (図 3.4 の灰色の実線、縦軸右) に対応する。稼働状態はロール機への入力速度、原材料の種類や混合状態で変化するが、図 3.4 は、稼働状態が振動データで分類可能であることを示している。

表 3.1 に CNN と RF の分類精度を示す。投入原材料が一定ではないために消費電力量と分類結果は細かく変動する (図 3.4)。このため、各カテゴリの境界付近では分類結果にブレが生じる。また、本システムでは厳密なカテゴリ分類を求めておらず、表 3.1 で示す精度は CNN,RF とともに実用上は問題ない。両者には大きな違いはなく、ベテランオペレータの意見も踏まえ実システムではやや精度の高い CNN を採用した。

以上の結果は、消費電力量などの重要な運転状態が振動データによって解析できることを示している。この開発結果を踏まえ、振動データを主な情報源として故障予知システ

力データとして使用した。

^{*2} 収集した加速度データには、ノイズも含まれているが、周波数特性から特徴はとらえられていると判断し、前処理は行わず解析を実行した。

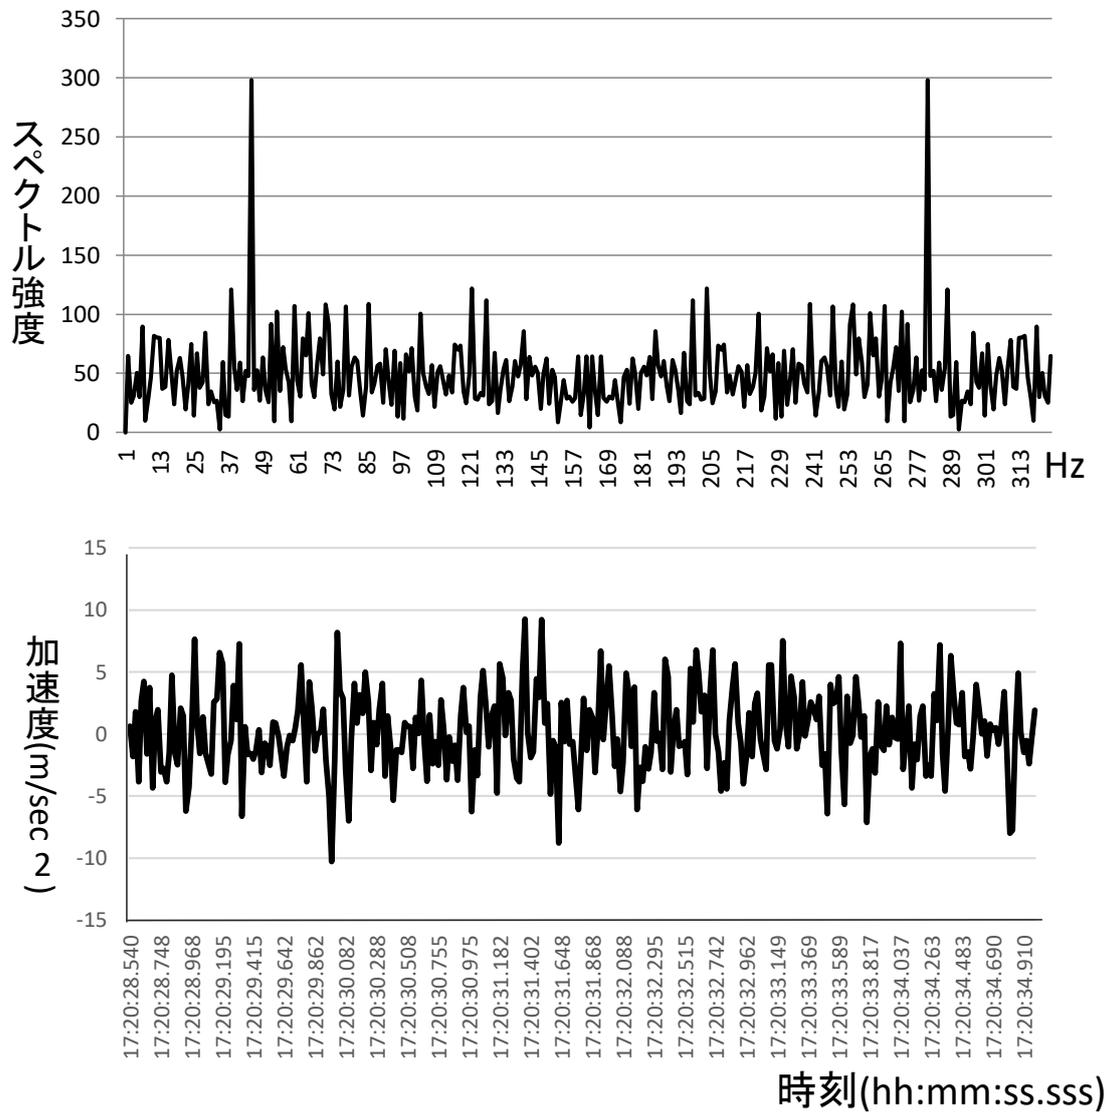


図 3.3 入力データの周波数特性 (上) と加速度値 (下)(従動系右側 X 軸)

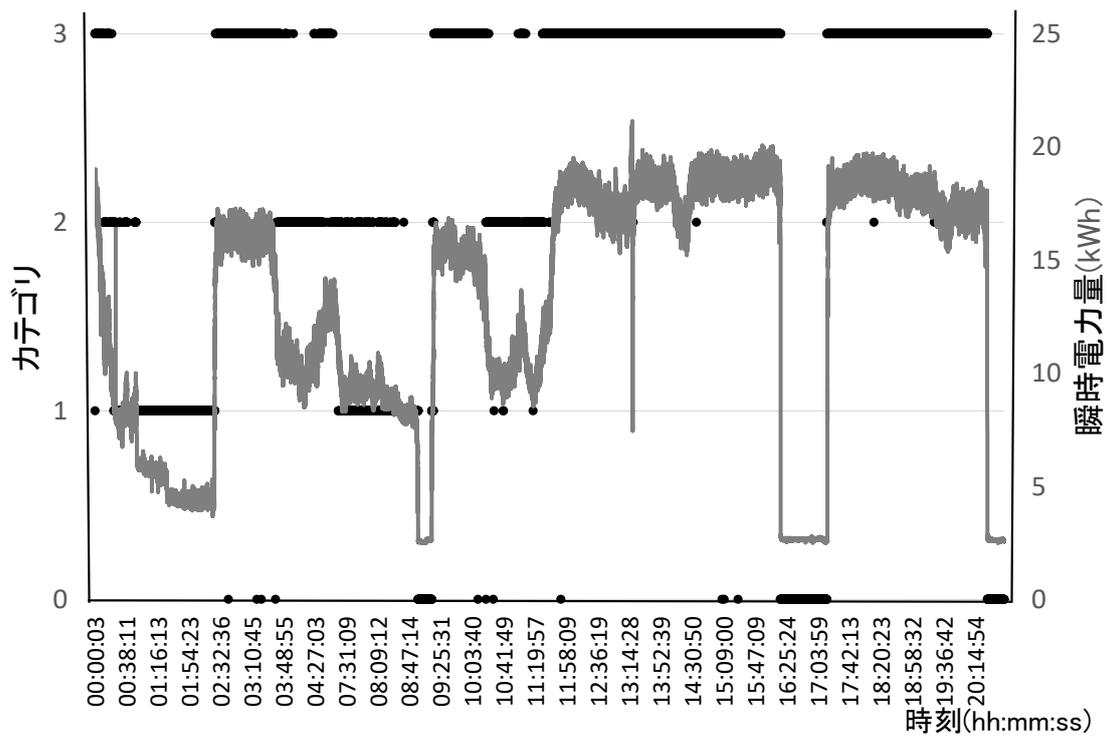


図 3.4 運転パターンと消費電力量の関係

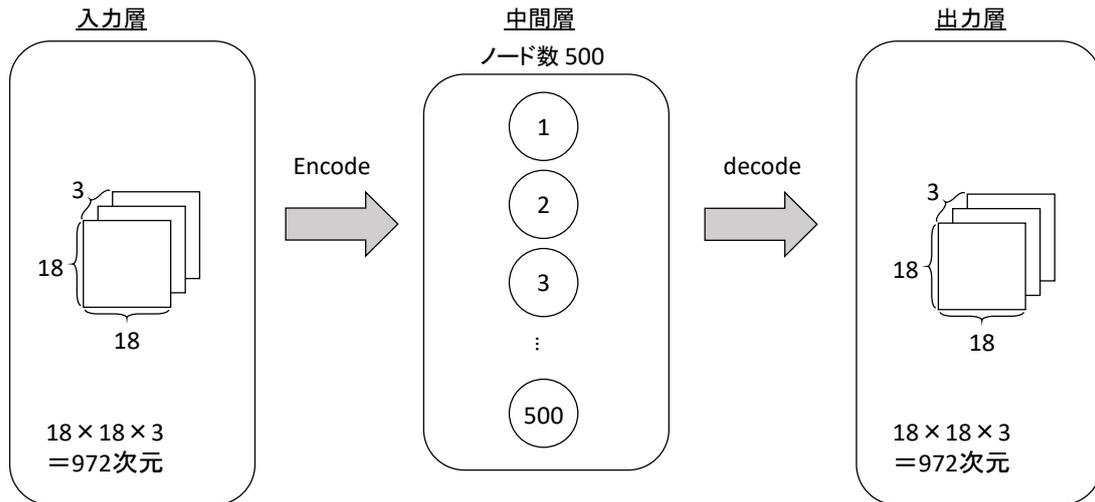


図 3.5 Autoencoder のネットワーク構成

ム、部品交換時期分析システムを開発することとした。

3.4 故障予知システム

故障予知と障害検知はプラントの運用で重要であり、多数の手法が提案されている。手法の有効性の確認のため、小型モータを用いた実験システムで振動データの解析を実施した。以下に示す検証結果に基づき、2つの手法を実環境に適用した。

3.4.1 手法の検討

実験システムでは、Autoencoder、疎構造学習、k-近傍法、密度比推定法の4手法を評価した。これら4手法は、実際のシステムでは異常データを収集することは困難な事から、正常運転時のデータの差から異常を検知する方法として選択した。

Autoencoder

Autoencoder [46] は、正常な運転状態のデータからモデルを作成するニューラルネットワークの一種である。使用データは、加速度値からFFTを実行して得られたスペクトル強度とした。

図 3.5 に示すように 972 次元の入出力と 500 次元の中間層から構成するネットワークモデルを使用した。中間層の次元数を 100 から 1000 まで変えて調べた入出力の差 (loss 値) を表 3.2 に示す。次元数を大きくする事で loss 値は減少するが、500 と 1000 では減少率

表 3.2 Autoencoder 中間層の次元数による loss 値の変化

項番	中間層次元	loss 値
1	100	101
2	250	98
3	500	95.5
4	1000	95

はわずかであり、計算量を考慮して 500 を選択した。Autoencoder では正常運用時のデータでは loss 値は小さく、loss 値を異常度とし閾値を設けることで異常検知を行う (実験結果は後述する)。ここで、loss 値 (異常度) E は、予測データ x 、観測データ x' 、入出力次元 $N(972)$ に対して以下のように平均二乗誤差とした。

$$E = \frac{\sum_{n=1}^N (\|x_n - x'_n\|)^2}{N}$$

疎構造学習

図 3.6 に示すように疎構造学習は、複数の時系列データ間の相関の崩れから異常を検知する方法である。ここでは、3 軸の加速度データを用い、これらの相関関係の強い軸間を抽出し、これを共分散選択アルゴリズムを用いて偏相関行列として表現し [44] [45]、学習データと観測データのそれぞれから生成された偏相関行列から計算したカルバック・ライブラー・ダイバージェンス距離を異常度とした [35]。

ここで、異常度は、学習データ D の偏相関行列 Λ 、観測データ D' の偏相関行列 Λ' 、 S を D の共分散行列としたとき、以下のように求められる $\alpha_i (i = 1, 2, 3)$ の最大値とした。

$$\alpha_i = \frac{1}{2} \ln \frac{\Lambda_{i,i}}{\Lambda'_{i,i}} - \frac{1}{2} \left\{ \frac{[\Lambda S \Lambda]_{i,i}}{\Lambda_{i,i}} - \frac{[\Lambda' S \Lambda']_{i,i}}{\Lambda'_{i,i}} \right\}$$

$[\cdot]_{i,i}$ は角かっこ内の行列の (i, i) 成分を抜き出す演算を表している。また、 S は Λ の逆行列である。

k-近傍法

図 3.7 に示すように、スライド窓により時系列データをベクトル形式に変換し k 近傍法を適用した [34]。具体的には、

Step1: 正常状態の観測値に対する部分時系列を D_{tr} とする。

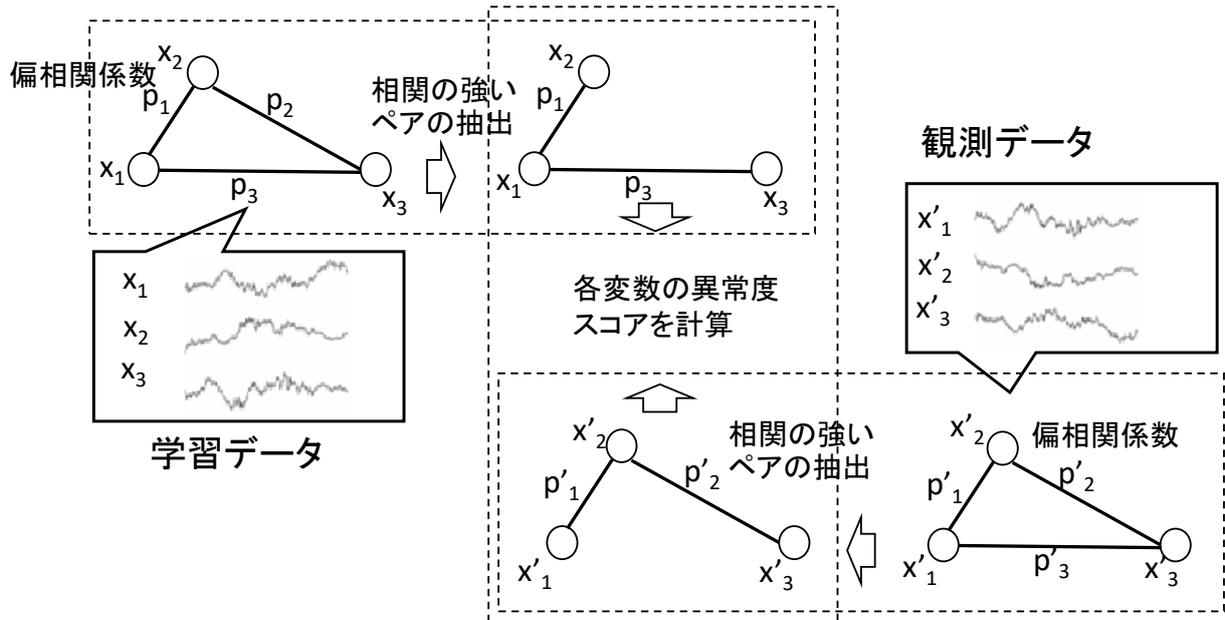


図 3.6 疎構造学習

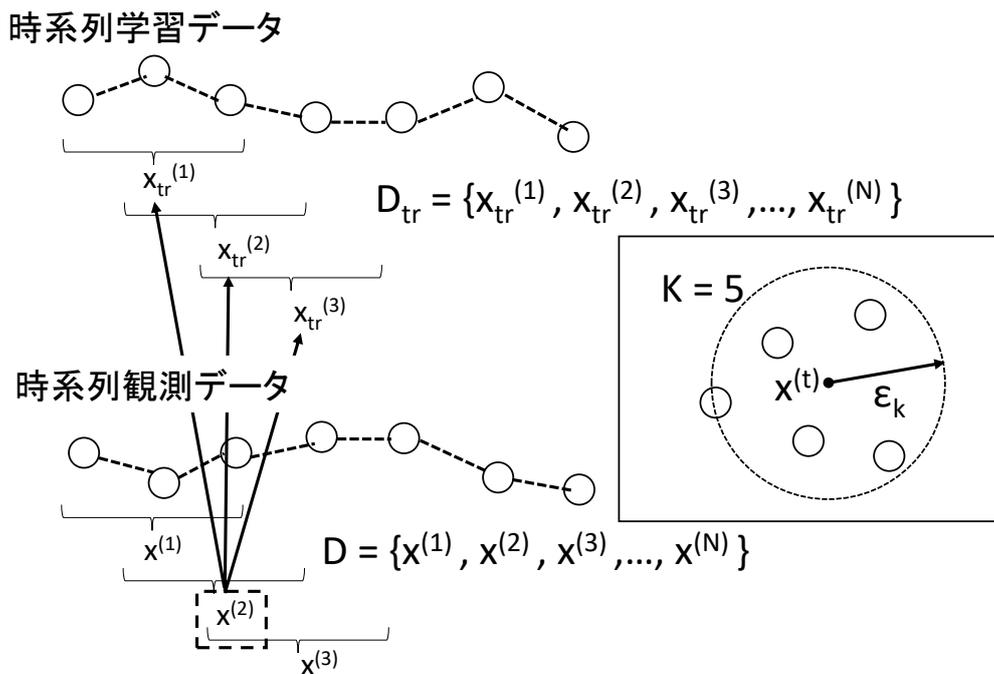


図 3.7 時系列データにおける k-近傍法

Step2: 異常検出の対象となる観測値 D と D_{tr} の距離を計算し D に対して、観測値 D に近い k 個の標本を D_{tr} から選んだとき、それらを囲む半径がある基準値 ϵ_k 以上ならば D は異常と判断する。

D は X 軸、Y 軸、Z 軸それぞれの N 点の加速度データである。本実験システムでは、加速度データと FFT 化したデータの両方が適用可能であり、それぞれを入力として評価を行った。

密度比推定法

密度比推定法 [35] は、正常時のデータと、異常を含む可能性のある新たに観測されたデータ、それぞれの確率密度関数を計算し、確率密度の比がしきい値を超えて異なる領域に対応するデータを異常と判定する。具体的には、 N の正常時の状態： $D = x_1, \dots, x_N$ と N' の新たに観測された状態： $D' = x'_1, \dots, x'_{N'}$ に対して、正常状態の確率密度関数を $P_{tr}(x)$ とし、新たに観察された状態の確率密度関数は $P_{te}(x)$ とし、密度比 $w(x) = p_{tr}(x)/p_{te}(x)$ を計算し、新しく観測された D' の最大 $-\ln(w(x))$ を D' の異常スコアとして使用する。実験システムでは加速度データを入力として評価を行った。

3.4.2 実験室での小規模実験

稼働中のプラントで実験を行う前に実験室で小規模な実験を行い、現場作業への影響を抑えた。具体的には、実プラントで想定される基本的な状態変化パターンについて、実験室環境の中、小型モーターの振動異常が各方法で検出できるかどうかを確認した。すなわち、前述の 4 つの方法を用いて、正常稼働中（一定の回転速度で一定の動作をしている間）に学習したモデルに基づいて人工的な異常の検出を試みた。

人工的な異常としては 1) 起動時、2) 速度の増加、3) 速度の減少、4) 不規則回転、および 5) 急停止のデータを用いた。また、入力データとしては、X 軸、Y 軸、Z 軸の 360 点の加速データとそれらの FFT により生成したスペクトル強度を使用した (Autoencoder では前述の通り 324 点 x3 軸のデータを入力とした)。

表 3.3 に検証結果を示す。Autoencoder, 疎構造学習, 密度比推定法の 3 つの方法ではすべての人工的な異常を検出できたが、 k 最近傍法では一部を検出できなかった。さらに、密度比推定法は、計算量が大きく、今回のケースでは学習に必要なデータ量が非常に大き

表 3.3 異常検知結果

手法	入力データ	起動	速度増加	速度減少	不規則回転	急停止
k-近傍法	スペクトル強度	非検出	検出	非検出	検出	非検出
k-近傍法	加速度	非検出	検出	非検出	検出	非検出
Autoencoder	スペクトル強度	検出	検出	検出	検出	検出
疎構造学習	加速度	検出	検出	検出	検出	検出
密度比推定法	加速度	検出	検出	検出	検出	検出

いことから現実的でない判断した。以上から、k-近傍法と密度比推定法を実プラントでの検証から除外した。

3.4.3 実プラントでの検証

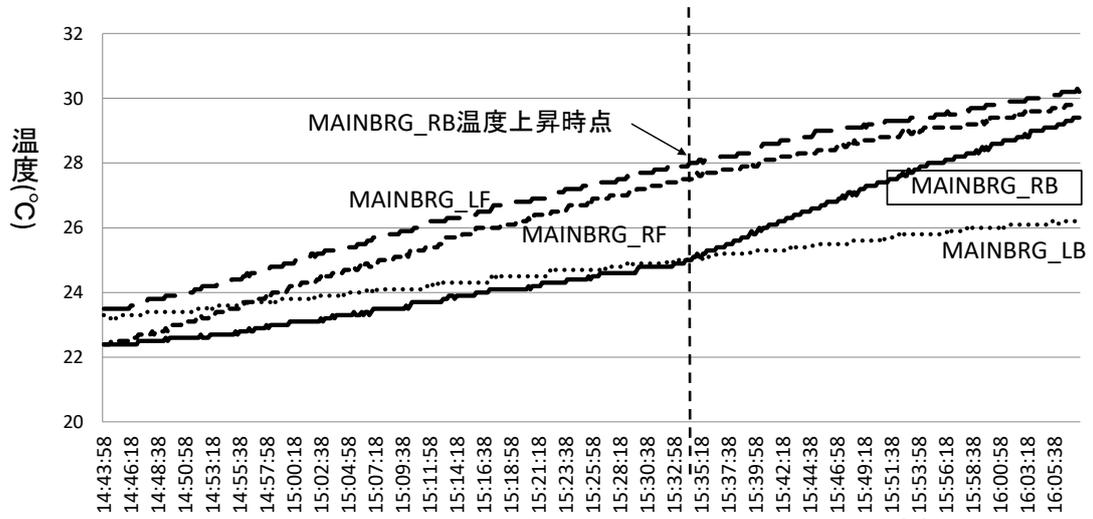
実験室でのプロトタイプ実験結果から、実プラントでの実証実験では、Autoencoder^{*3}と疎構造学習を適用した結果、以下で説明するように実際の異常を検出できた。

ベアリングでの温度異常:

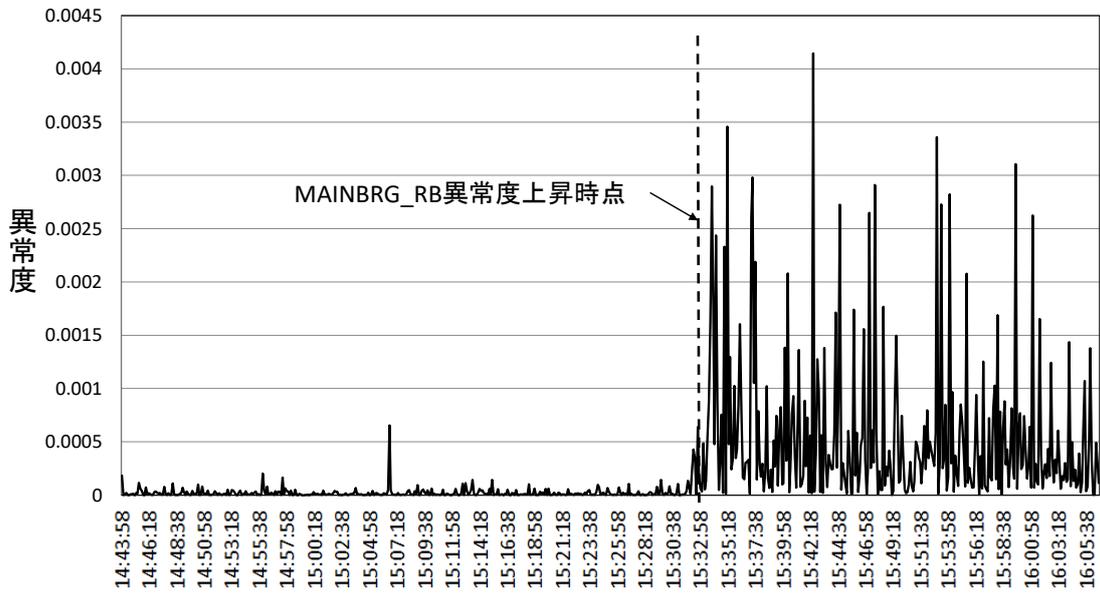
実証実験での評価中、ベアリングでの温度異常が発生した。図 3.8 に当該ベアリング (MAINBRG_RB) の温度と振動データの異常度スコアの推移を示す。ベアリングの温度は、機器の稼働状態により緩やかに変化するが、通常各ベアリング間の温度間隔は図 3.8 左側の MAINBRG_LF と MAINBRG_RF の様にほぼ一定である。しかし、図 3.8 では 15:34~15:35 に MAINBRG_RB の温度が MAINBRG_LB の温度を超え、その後両者の温度間隔が大きくなっており MAINBRG_RB において温度異常が発生している。^{*4}一方、疎構造学習の異常度スコアは、15:33 頃に正常時の 0.0001 から 0.0005 程度に増加、温度異常の発生時点の 15:34~15:35 には 0.002~0.003 と正常時の 20 倍 ~30 倍に急増している。このケースは、温度変化の観測結果に加え、疎構造学習で振動データを解析することで予知の信憑性を高めることができる事を示している。

^{*3} 後の検証により 5 章で示す CAE(Convolutional Autoencoder) のほうが異常検知性能に優れていることが判明し、現在では CAE を適用している。

^{*4} この事例のような温度変化は、単純なしきい値監視は困難であり、疎構造学習の異常度変化を検出する方が確実であると考えられる。



(a)ベアリング(MAINBRG_RB)温度上昇 時刻(hh:mm:ss)



(b)疎構造学習の異常度推移

図 3.8 ベアリングで温度異常を検知

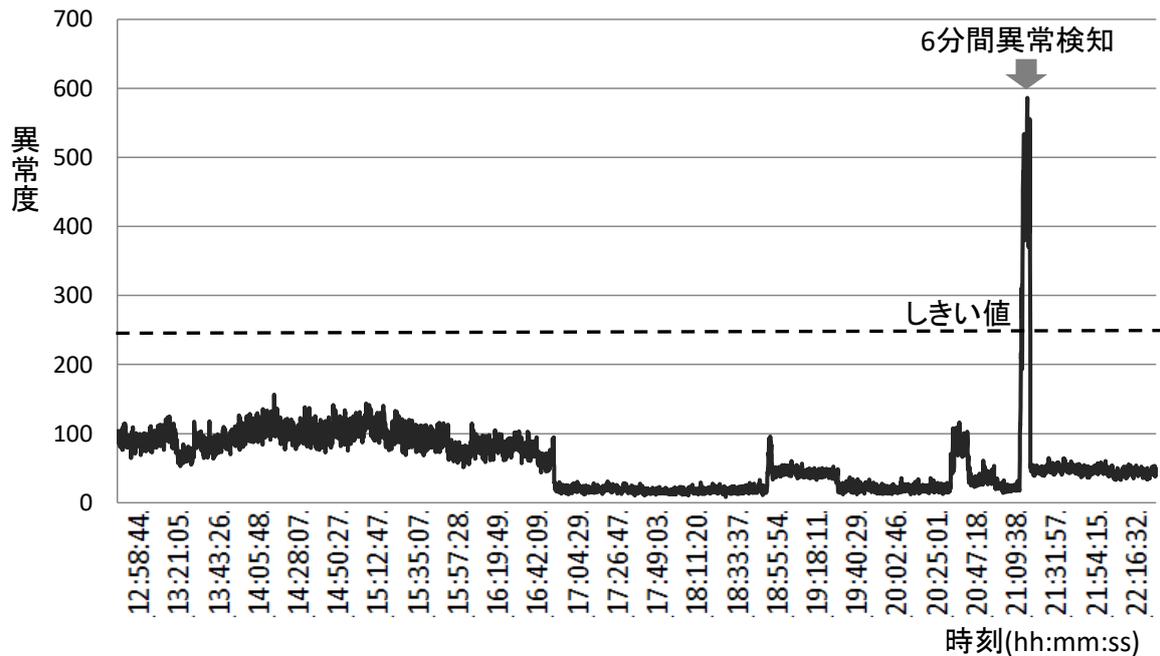


図 3.9 メインモータで振動異常を検知

メインモータでの異常:

図 3.9 は Autoencoder の異常度スコアが 6 分間にわたりしきい値 250 を超えたケースである。しきい値は、数か月間運用で通常時の異常度スコアが概ね 250 を超えることがなかったことから採用した値である。Autoencoder の異常度スコア以外メインモータは正常に稼働しているように見えるが、その後、同様のイベントが複数回観察された。現時点において実際に機器の故障は発生していないが、このタイプの異常の増加は、隠れた問題を示唆している可能性があり、今後実際の異常との関連性を監視する。

Autoencoder ではベアリングの温度上昇は検出できず、疎構造学習ではメインモータの異常は検出できなかった。これらの結果は、どちらの方法も完全ではないことを示唆している。2つの手法の組合せでの異常検知が現実的であり、実運用では Autoencoder と疎構造学習の両方を利用することとした。

3.5 部品交換時期分析システム

ロール機では、原材料を砕く主ロールは定期交換部品である。部品交換時期を後ろに延期できればプラントの運用コストは低減するし、異常の徴候が出た時に早目に交換し事故

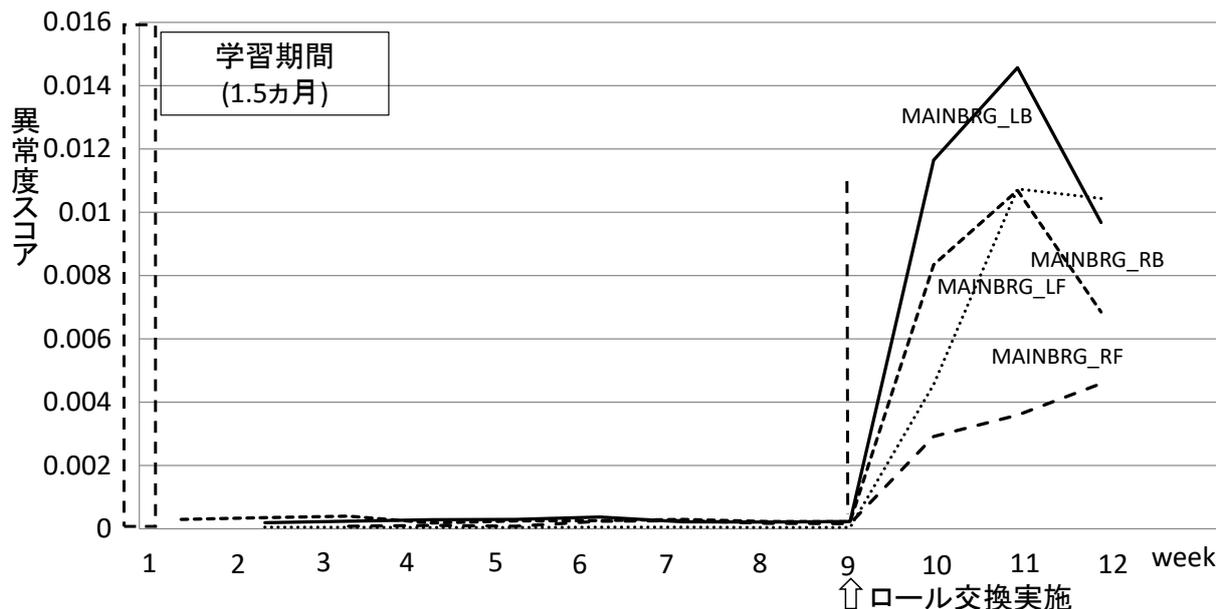


図 3.10 ロール交換前後での疎構造学習異常度の推移

を防ぐ事でもコストは低減する。状態監視システムおよび故障予知システム開発の経験から、振動パターンを CNN および疎構造学習で分析する事による部品交換時期の分析を試みた。

図 3.10 は、ロール交換前から後の 12 週間にかけて振動パターンを疎構造学習で分析し、異常度の推移を示した図である。ロール交換は 9 週目の最終日に実施しており、交換後の振動パターンの異常度は、交換前を正常とした場合に、50 倍から 100 倍に急増している。この事実は、疎構造学習でロール交換前後での主ロールの状態変化を区別できることを示している。新しく取り付けられた主ロールと、長期間の使用により歯が摩耗した主ロールは、異なる振動パターンを持ち、疎構造学習は両者の違いを検出できている。以上の結果から、ロール交換前後の振動データを用いたロール交換時期の分析モデル作成を試みる事とした。

分析モデル生成には疎構造学習に加えて CNN の手法も試した。学習データには、ロール交換前後の 2 カ月間のデータを用いた。疎構造学習では、観測データから交換前後それぞれの学習データに対する異常度を計算し、異常度の小さい方を判定結果とした。CNN でも、同様に観測データを交換前後に分類するモデルを作成した。図 3.11 に CNN によるロール交換前後の交換後判定比率の推移を示す。ここで交換後判定比率は、1 週間のデータの中で交換後と判定された観測データの出現割合である。9 週目から 10 週目でロール

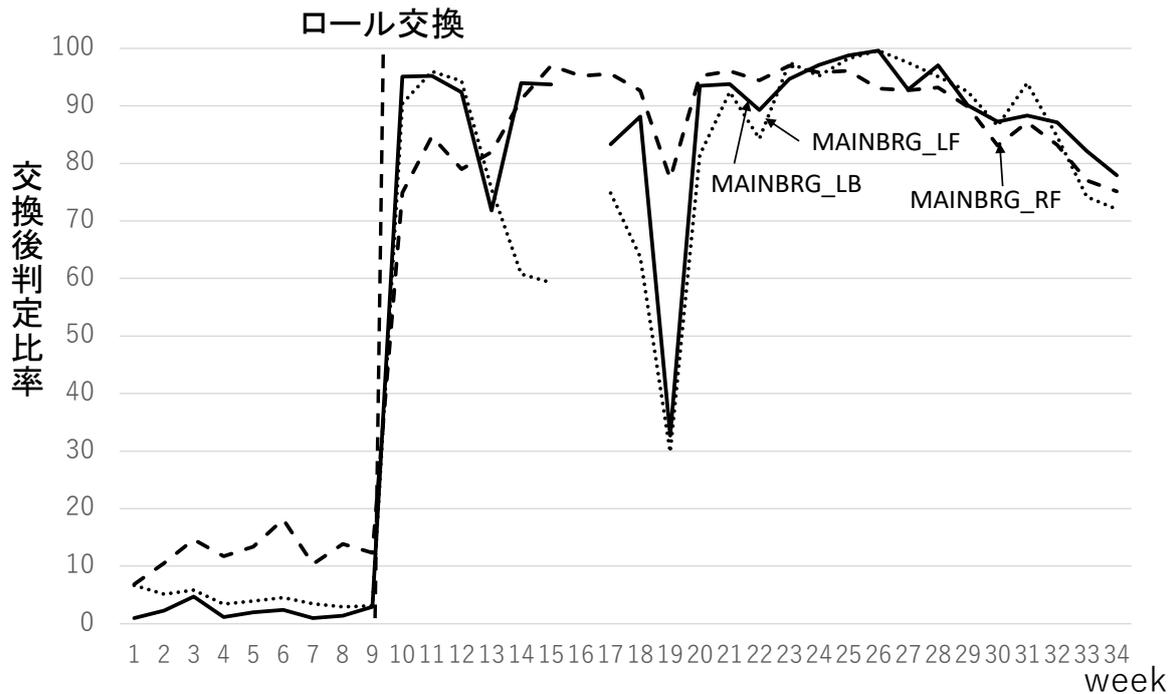


図 3.11 CNN によるロール交換前後の交換後判定比率の推移

交換に伴い交換後判定比率が逆転していることが確認できる。ロール交換前では交換後判定比率が 20% 以下であるのに対して、ロール交換後では概ね 80% を超えている。すなわち、交換後判定比率によって主ロールの状態を確認できている。交換時期は、疎構造学習および CNN による観測データの交換前後判定比率を週毎に計算し、しきい値と比較する事で判断する事とした。

なお、交換時期を決めるしきい値は図 3.11 の 34 週目までの値から外挿し概ね交換後判定比率 20% と想定しているが機器の固体差等の影響を分析しきれておらず、最適な値は今後の評価を通して決定する。ただし、現状のシステムでも急激に値が変化した時には早目に交換する等の判断材料を提供可能であり、予期しない故障によるコスト増の削減には効果が見込める。また、実運用には、CNN および疎構造学習のうち、3.6 節で示す収集データ量の削減評価の結果から削減による精度が落ちにくい CNN を選択した。^{*5}

^{*5} 図 3.10 のデータが 12 週までなのは、途中から CNN の計測に集中した事による。また図 3.11 の 16 週と 19 週は収集システムに不調が確認されており正しくデータ収集できていない。これらのデータは学習データから除外したが以降は順調にデータは取得されている。

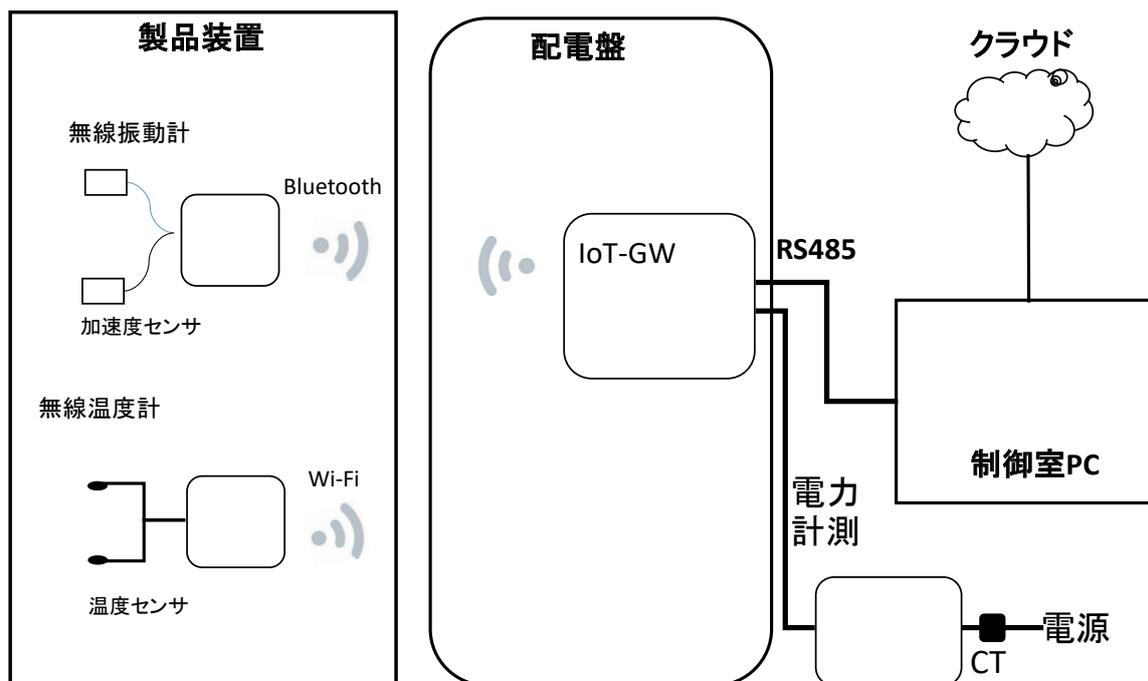


図 3.12 データ収集システムの構成

3.6 データ収集システム

監視システムは、加速度データや温度データを含めた様々なセンサーデータを使用する。センサーおよび通信方法は、開発時点で一般に流通している機器の中から、価格・性能面を考慮して妥当と思われるものを選択した。本システムでは、通信方式として、温度センサーは Wi-Fi、加速度センサーは Bluetooth、電力計は RS485 を用いた。

飼料プラントの環境はコンピュータの運用には適していないため、監視用の PC はセンサー (装置) から離れた制御室に設置した。このため、PC にデータを転送するために装置の周辺に IoT-GW を設置した。すなわち、センサーから収集したデータは、IoT-GW で一旦集約し、IoT-GW が制御室の PC(Personal Computer) に転送する構成とした (図 3.12)。データ解析は、クラウド上、もしくはクラウド経由でデータを取得した工場外の設備を使って実施した。

IoT-GW は粉塵対策のため、プラスチックケースに格納した。このため IoT-GW は効率的に熱を放散できず過度の熱を発生させないように機能を制限した。具体的には、ファイアウォールは PC にインストールして外部環境からセンサーシステム全体を保護する構成とし、IoT-GW からセキュリティに関する処理を削除し、通信処理機能に絞った構

成とした。

IoT-GW はセンサーから数メートル程度の位置に設置したが、実プラントの環境では、実験室では確認できなかった電磁波や遮蔽物の影響で IoT-GW とセンサー間は最適な通信環境が保証できないことが判明した。このため、センサー付属の通信機器で比較的安定な通信が達成できる通信帯域の選定と、各種再試行処理を組み合わせ、以下のサンプリングレートでデータを収集できるようにセンサーを設置した。

- 加速度センサー: 50Hz
- 温度センサー: 0.1Hz
- 電力計: 1Hz

上記サンプリングレートは、各センサーの仕様、センサーと IoT-GW 間および IoT-GW と PC 間の通信帯域と状態監視、故障予知、部品交換時期分析の各システムでの解析精度を考慮して設定した。

本サンプリングレートでは、加速度センサーからの振動データの量が特に多い。振動データのデータ収集と解析に係るコストを削減するため、データ解析への影響を与えない必要最小限のサンプリングレートとデータ収集周期を以下の手順で求めた。さらに、振動センサー自体のコスト削減も考慮し、3軸センサーから1軸センサーへの変更も検討した。表 3.4 は、状態監視、故障予知、部品交換時期分析の各システムで必要となるセンサー種別、サンプリングレート、データ収集周期の解析への影響を示した表である。表 3.4 の値は、故障予知では、異常度スコアの時間推移に対し 3 軸/50Hz, 常時収集のケースとの相関値であり、状態監視、部品交換時期分析では、3 軸/50Hz, 常時収集のケースとの分析結果の一致率である。状態監視の場合、CNN では 1 軸 (Y 軸) の振動センサーからの 25Hz のサンプルレートで十分である*6。故障予知では Autoencoder を用いた場合、1 軸 (Y 軸) 振動センサーで 10Hz のサンプリングレートで十分である。しかし、CNN による部品交換時期分析には、3 軸振動センサーで 25Hz のサンプリングレートが必要である。

以上から通信量とセンサーコストの削減のため以下のようにセンサーを設置し、データ収集システムを構築した (表 3.4 太枠)。

*6 3.3 節で議論したように状態監視では高い精度は必要ない。ただし、部品交換時期分析では、表 3.4 に示されている適用可能な範囲に影響するため、精度への配慮が重要である。

表 3.4 サンプルングレート、データ収集周期、センサー種別のデータ解析への影響評価

MAINBRG_RF							
センサー	収集周期	サンプルング レート	故障予知		状態監視	部品交換時期予測	
			Autoencoder	疎構造学習	CNN	CNN	疎構造学習
3軸	常時	25Hz	1.00	0.99	57.9%	81.5%	67.3%
		10Hz	0.99	0.99	No test	No test	No test
	1日おき	50Hz	0.87	0.96	88.4%	86.8%	66.7%
	週1日	50Hz	0.51	0.89	86.5%	93.4%	60.9%
1軸-Y	常時	25Hz	0.97	NA	79.2%	78.9%	NA
		10Hz	0.98	NA	No test	No test	NA
1軸-Z	常時	25Hz	0.96	NA	64.5%	71.7%	NA

故障予知の判定基準：
異常度スコア推移の相関
(3軸, 50Hz, 常時のケースとの比較)

状態監視/部品交換時期予測の判定基準：予測結果の一致率
(3軸, 50Hz, 常時のケースとの比較)

 : 適用可能

- 3軸振動センサーを1つのベアリングに装着し、週1日で収集、50Hz サンプリングレートで部品交換時期分析に利用した。3.5節で議論したように、ロール交換前と後の振動パターンの変化は、メインモータを除く各センサーに現れている。このため、1つのロール交換時期を、このベアリングの振動データから判断する事とした。
- 1軸 (Y 軸) 振動センサーを監視対象とする全てのベアリングに装着し、常時収集、50Hz サンプリングレートで状態監視および故障予知に利用する構成とした。このケースでは、25Hz サンプリングレートでも満足するが、通信帯域を考慮して 50Hz サンプリングレートが適用可能と判断した。

3.7 開発システムの特徴

開発システムの特徴を以下にまとめる。

- 状態監視システム

振動データからプラントの状態を理解できるようにするためのステータス監視用のラベル付け機能を開発した。これにより、稼働状態が振動データでカテゴリ分類可能であることを確認するとともに、振動データを用いた故障予知システムと部品交換時期分析システムの開発の妥当性を確認した。

- 故障予知システム

解析手法の有効性の事前確認のため、小型モータを用いた実験システムで振動データの解析を実施した。実験システムでは、正常運転時のデータの差から異常を検知する4手法を検討し、実システムにおいては、人工的な異常の検出精度、計算時間の観点から Autoencoder と疎構造学習を採用した。さらに、これらの手法は実プラントで有効性を確認した。

- 部品交換時期分析システム

ロール機の定期交換部品である主ロールの適切な交換時期を、1週間の観測データの振動パターンを交換前後に分類し、その出現割合から判定できることを示した。

- データ収集システム

データ収集システムの全体設計を行い、解析手法毎に、データ解析に影響を与えない必要最小限のサンプリングレートとデータ収集周期を求めた。

3.8 開発プロセスと技術選択の留意点

以上説明してきた開発プロセスの留意点を以下にまとめる。

- 監視データの選択

プラントが異常状態になることは稀なため、状態監視システムの開発から開始した。センサーを用いた通常運用状態の確認は重要であり、始めに振動データから状態判定が可能である事を確認した後に異常を非正常状態として取得する異常検出機能の設計に着手した。

- 実験室での小規模実験

実験室での小規模実験により適用可能な手法を絞り、稼働中のプラントで実験を行う事による現場作業への影響を抑えた。また、大量かつ複雑な稼働条件下での実プラントで想定される基本的な状態変化パターンを抽出して単純化することで手法の選定を容易にした。

- データ収集速度

適切なセンサーの選択と、分析のためのデータ収集間隔とサンプリングレートの決定方法について、状態監視、故障予知、部品交換時期分析の各目的毎に検討することにより、データ収集とデータ解析コストの削減を試みた。

- システムの全体設計

本システムでは、収集データは IoT-GW を設置し制御室に設置した PC を経由してクラウドに転送する構成とした。これは、プラント環境では十分な計算機パワーを得ることが困難であることに加えて、Wi-Fi や Bluetooth の短距離通信が電磁波等の影響で安定性に欠けるためである。

データ解析手法とそれに必要なデータ収集速度は、設計のポイントである。前節で議論したような複雑な稼働条件下での検証を効率化するため、予備実験と実プラントにおける検証を繰り返すことで適切なデータ解析手法とデータ収集手法を決定した。

以上、本システムではシステムの全体性能とコストを考慮したデータ収集システムを構築し、状態監視システムでは CNN を、故障予知システムでは Autoencoder と疎構造学習

を、部品交換時期分析システムでは CNN を選択した。

3.9 むすび

本研究では、飼料プラントにおいて、原材料の粉碎装置であるロール機を対象とし、故障の生じやすい駆動部に振動センサーと温度センサーを設置しセンサーデータを収集、また、消費電力量も収集しこれらのデータを分析するプラント監視システムを開発した。具体的には、状態監視システム、故障予知システム、部品交換時期分析システムおよびこれらを支えるデータ収集システムの開発について報告した。監視システムの構築を通して、収集されたデータを分析するための適切な方法の選択プロセスや既存の古い装置からデータを収集する上での考慮点、など、システムを設計する過程での留意点を明確にした点が本研究の主な貢献である。更に、ここで説明した設計方針に従い、Autoencoder と疎構造学習が飼料プラントの故障予知に有効であることを示した。

第4章

プラント監視データ収集システムに関する研究

4.1 はじめに

本研究では、3章で述べた予知保全を目的としたデータ分析に必要な十分なデータ量を収集できるシステムを構築するための課題を議論する。IoT/CPS(Cyber Physical Systems)のデータ収集のための通信ネットワークに着目した研究は、表 2.1 研究分野#6 に示すように、適用例ごとに要求されるデータ収集量と通信容量、具体的な通信手段を提案したり、無線通信におけるデータロスへの取り組みがある。しかし、これらの研究は機能・仕様の検討が中心で、実プラントにおけるノイズの評価と分析手法が要求するデータ収集性能などシステム導入時に直面した具体的な課題や定量評価を含めた対策までは踏み込んでいない。1章で述べたように、本研究では、工場内の電波環境の問題からノイズ影響の対策が必要であった。データ通信におけるノイズ影響に関しては、石田ら [71] が、電子機器・装置のノイズ波源位置・大きさを探知する技術を提案している。また、電子情報通信学会 [72] では、電波雑音の測定方法を示している。しかし、本研究で対象とするプラントでは多様なノイズ源が考えられ、その特定及び対策はコスト面から現実的ではない。

本章では、3章で述べた故障予知や部品交換時期分析を目的としたデータ分析に必要な十分なデータ量を収集できるシステムを構築するための課題として、(1) 全体システム構成、(2) センサー、IoT-GW の選定 (性能、コスト、消費電力) と設置、(3) 通信手段の選定と安定性、通信性能の確保について、実証実験システムの構築を通して議論する。特に工場内では電波環境が悪く、安定的な通信の実現に注力する必要がある。本章では、不安定

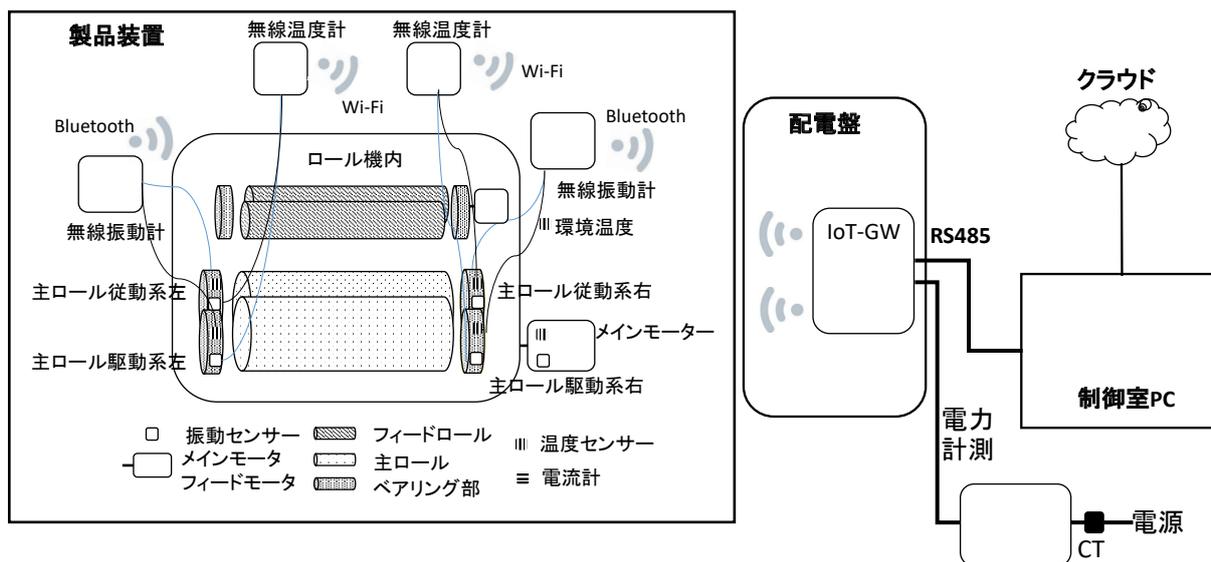


図 4.1 監視対象機器とデータ収集システム

な通信環境を前提に、データ通信の自動回復処理で対応、通信のリセットタイミングの調整方式を提案し、その有効性を評価する。

4.2 データ収集システムの要件と構築上の課題

4.2.1 分析対象の飼料工場と監視対象機器

図 4.1(図 3.1 を再掲) に本研究で対象とする飼料工場に設置された監視対象装置とデータ収集システムの概要を示す。図 4.1 に示した監視対象装置 (ロール機) は、3 章で詳述した原材料を粉砕し所望の粒度の粉体を生成する装置である。この装置はメインモータの動力が主ロール駆動側、主ロール従動側に順に伝えられ、ロール部で原材料を粉砕する。ベアリング等の駆動部が故障を生じやすい部品で、故障による生産プラントへの影響が大きく、監視対象である。3 章で詳細を報告したデータ分析システムは監視箇所の振動データを主たる情報とし、電力量と温度データも分析の信憑性を高めるための補足情報として利用した。また、振動データは、定期交換部品の適切な交換時期分析にも利用した。

4.2.2 データ収集システムの要件

3 章で詳述した故障の検出と交換部品の適切な交換時期分析を目的としたデータ分析手法は、データ収集システムが以下の要件を満す事を必要としていた。

- 監視対象装置

設置後数十年経過した古い既存機械設備に新しいIoTベースの監視システムを導入する。この目的のため、センサー、通信ネットワーク、IoT-GWを新規に導入し、工場内の設置場所の離れた既存機械装置から振動データ、温度データ、電力データを収集する。この際、既存の設備の動作に影響を与えないように外付けで機器やセンサーを限られたスペースに適切に設置する、電源ケーブルや通信ケーブルなどの敷設経路を確保するなどの諸課題がある。

- コスト要件

システム構築では、ローコスト化、データ収集の安定性確保を考慮する必要がある。

- プラント監視システム

収集データはクラウドに集約して分析、可視化する。これらは、遠隔地で参照できる必要がある。

- センサー数

装置当たりのセンサー数は、振動センサー、温度センサー各5台(主として駆動部に設置)、電力計1台とする。

- 収集データ量

データ分析に必要な各センサーあたりのデータ収集頻度(サンプリングレート)は以下の通りである(3章参照)。

- 振動データ(3軸): 50Hz
- 温度データ: 0.1Hz
- 電力データ: 1Hz

本研究の目的は上記要件を満すデータ収集システムを構築する事にある。

4.2.3 データ収集システム構築上の課題

データ収集システム構築上考慮すべき要件は、(1) 全体システム構成、(2) 性能、コスト、消費電力を考慮したセンサー、IoT-GWの選定と設置、(3) 通信手段の選定と安定性、通信性能の確保である。

このうち、通信の安定性に関して、システム導入時、遮蔽物や電磁波影響等によるセンサーとIoT-GW間の短距離通信(Bluetooth)の切断が頻発した。特に当初機器仕様のみ

で設計した Bluetooth 通信の切断頻発は、人手によるセンサーリセット操作が必要となり、運用の大きな障害要因になった。

図 4.2 に異なる場所に設置した各装置における 1 日の Bluetooth 通信切断発生回数 (120 秒以上のデータ欠損が発生した回数) を示す*¹。装置 A、装置 B では日によって発生時間帯が異なりどの時間帯でも発生しうる。装置 C は全般に発生頻度が低い。このような通信切断は 1 日に数十回以上になるが、周辺の機器も含めて機器の稼働状況との連動性は確認できず、発生原因は不明であった。また、これらは実環境のみで発生し、実験室では再現できなかった。これらのノイズ影響に対しては、発生源を調査して対策することもことも考えられるが [71][72]、調査費用の問題や将来の対象機器周辺の環境変化も想定し、後述のデータ通信の回復処理で対応することとした。

4.3 課題解決策

4.3.1 データ収集システムの全体構成

クラウドへのデータ転送方式として、(1)IoT-GW から PC に一旦集約してからクラウドに転送する方式、(2)IoT-GW からクラウドに直接転送する方式、の 2 方式を検討した。公衆網へのアクセスポイントが 1 ヶ所で通信コスト面で有利であること、セキュリティ対策も集約できることから図 4.1 に示した様に一旦 PC に集約する方式を選択した。IoT のネットワークセキュリティは主要課題の 1 つであり多くの研究が行われている [73][74][75]。しかしながら特にセンサーネットワークでは課題も多く実用上は十分でない。一方、PC と IoT-GW はクラウドへのアクセスポイントとして同等のセキュリティ対策が必要であるが、PC のほうが実用上の安全対策が進んでいると判断し、また、3 章で述べたように IoT-GW の処理負荷低減のため、PC によりクラウドへのアクセスを 1 か所にする事で安全性を高め効率的なセキュリティ対策を実現した。

4.3.2 センサー及び IoT-GW の選定と設置

- センサーの選定と設置

振動を計測するための加速度センサーは開発時点で一般に流通している機器の中か

*¹ これらは、後述する対策導入後に動作ログから抽出し結果として判明したものである。導入前のデータは人手によるセンサーリセット操作の影響で記録できておらず、ここでは対策後のデータを示す。

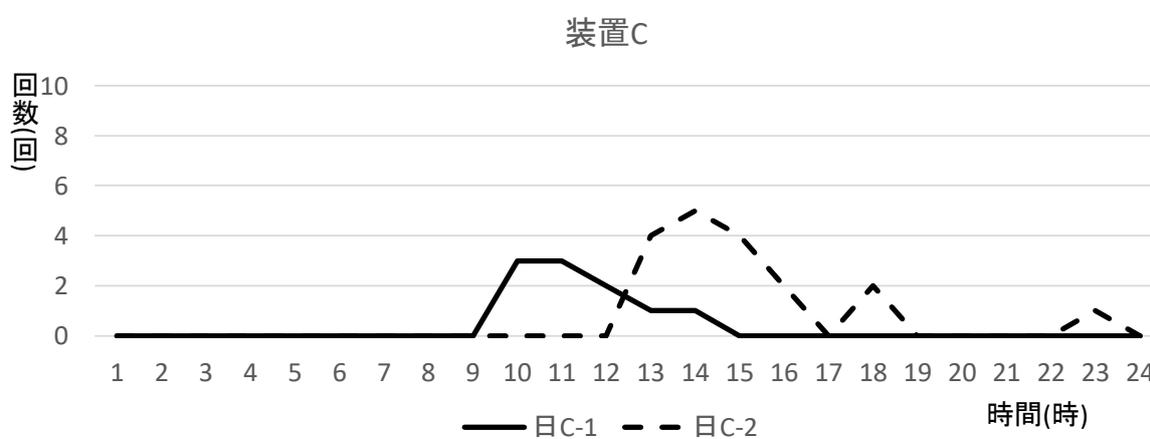
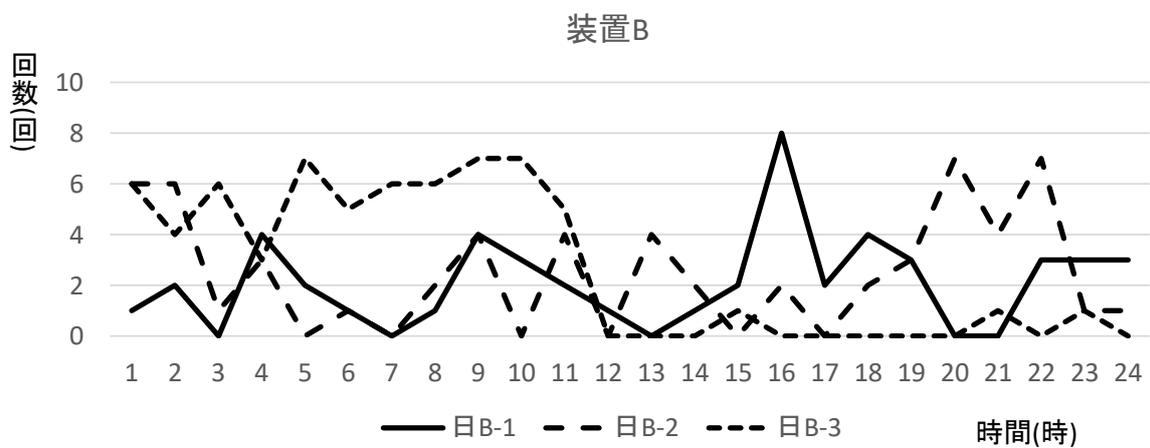
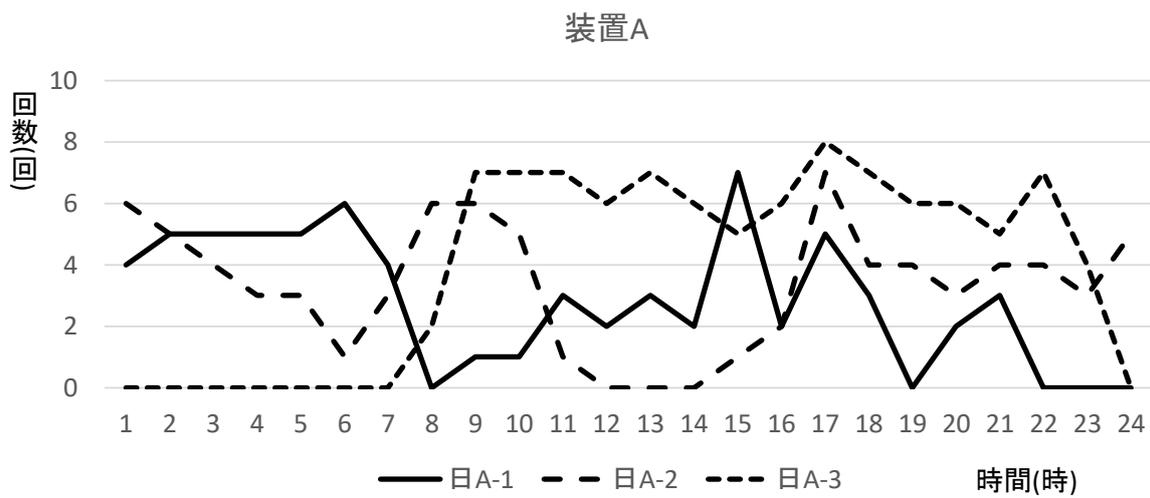


図 4.2 通信切断回数の推移

表 4.1 センサーと IoT-GW 間の通信方式

項目	Bluetooth	Wi-Fi
規格	IEEE802.15.1	IEEE802.11b/a/g
周波数	2.4GHz	2.4GHz/5GHz
到達距離	10m～100m程度	100m～300m程度
伝送速度	1Mbps	11Mbps/54Mbps
送信出力	2.5mW程度	30mW程度
消費電力	120mW以下	3W程度

ら精度、性能、設置性、価格を考慮して妥当な機種を選択した。このとき、通信手段の選択肢は Bluetooth 通信であった。

温度センサーは Wi-Fi および Bluetooth 通信が選択肢であったが、高い送信出力による安定性から Wi-Fi を選択した (表 4.1[76] 参照)。消費電力は Bluetooth が有利であるが、センサー用の 100V 電源を準備できたことから問題にはならなかった。

電力計は無線タイプの機種も存在したが、IoT-GW と近距離での設置が可能であり通信の安定性を考慮しシリアル通信 RS-485 の機種を選定した。

センサーは各装置の監視箇所にマグネットで設置し、特に加速度センサーでは設置位置・方向は正確に記録し装置のメンテナンス等で取り外した場合も正確に設置を復元できるように運用した。また、センサー部と付属する通信部間のケーブルおよび電源ケーブルの敷設では、適切な経路を選定し、既存の設備の動作への影響を防いだ。

- IoT-GW の選定と設置

監視対象装置当たり 1 台の IoT-GW を設置した。IoT-GW 機器は要求データ量を処理できる性能スペックを有し、センサー及び PC との通信に必要なインタフェース (Wi-Fi, Bluetooth, RS-485) を具備していることを条件として選定し、防塵対策のためプラスチックケースに収容した。また、監視対象装置周辺に設置可能な大きさと形状を配慮し、配電盤内に設置した電力計から RS485 で引き込むために監視対象装置の配電盤付近に設置した。

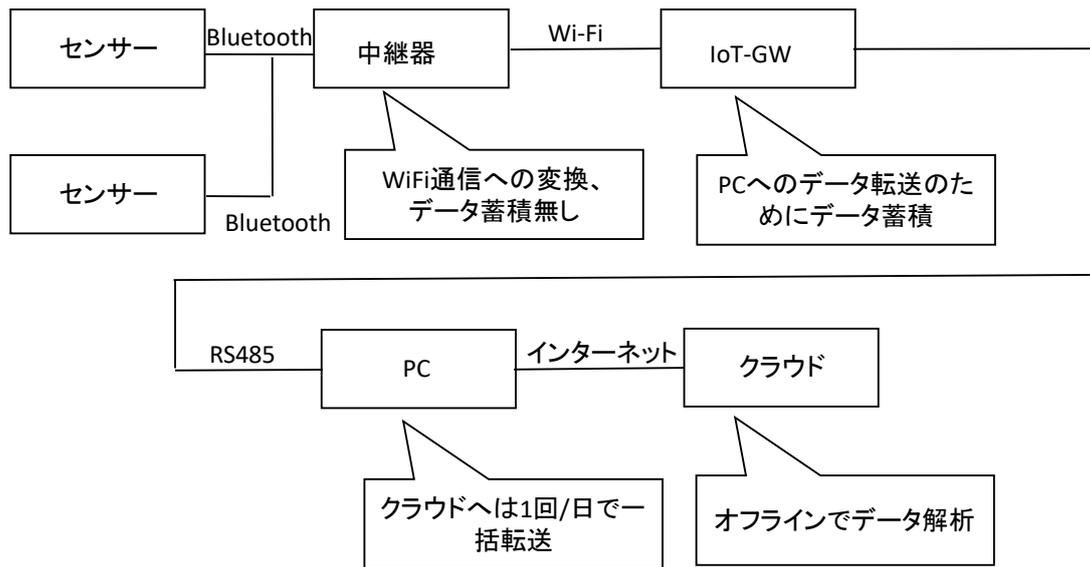


図 4.3 データ収集システムのデータ転送手順

4.3.3 通信方式

全体構成

図 4.3 に加速度センサーで収集したデータをクラウドに転送するまでの手順を示す。センサーで収集したデータは、通信の安定化対策のため中継器で Bluetooth から WiFi へ変換する（詳細は後述）。中継器では、受信したデータを蓄積せず IoT-GW に Wi-Fi 通信で転送する。なお、温度センサーで収集したデータは Wi-Fi で直接 IoT-GW に転送、電力計のデータは RS-485 にて直接 IoT-GW に転送する（図 4.3 には含めず）。IoT-GW でデータを蓄積し、PC から RS-485 通信上でポーリングする方式で PC にデータ転送する（詳細は後述）。

IoT-GW 上にデータを蓄積することで通信路や PC のトラブルで PC へのデータ転送が一時的に停止しても IoT-GW に蓄積したデータでデータを再現可能な構成とした。PC からデータ分析用のクラウドへは 1 回/日で一括してアップロードすることとした。

センサーと IoT-GW 間の通信方式

センサーと IoT-GW 間の通信速度に関しては、3 章で述べたサンプリングレートの必要要件に対し、後述するように十分余裕がある。しかし、前述のように加速度センサーで使用する Bluetooth の通信は不安定であった。この理由は、表 4.1 に示すように Wi-Fi の送

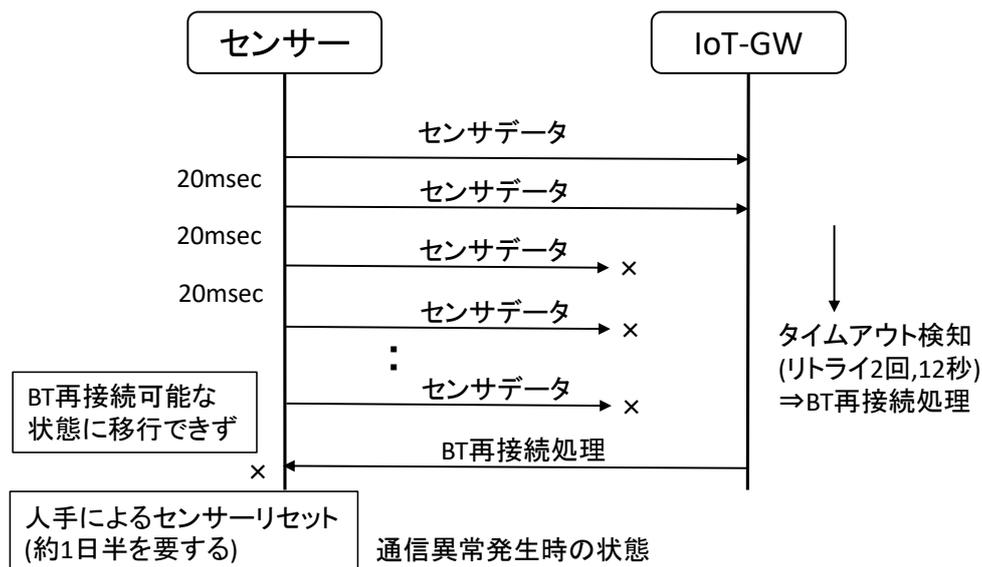


図 4.4 Bluetooth 通信安定化の課題

信出力は 30mW であるのに対して、Bluetooth の送信出力は 2.5mW であり、遮蔽物や機械設備 (モータ等) の発する電磁波の影響を受けやすいことが考えられる。

図 4.4 にセンサーと IoT-GW 間の Bluetooth 通信の手順を示す。図 4.4 に示すように IoT-GW 側では、センサーデータの受信に失敗すると、2 回のリトライを実施し不成功の場合は Bluetooth 再接続処理に移行する。リトライ不成功の判断まで 12 秒としたが、この時間は実装した IoT-GW の Bluetooth ソケット生存時間に基づき設定した。対策前のシステムでは IoT-GW 側でリトライタイムアウトを検出してもセンサー側で Bluetooth (図では BT と略記) 通信を再接続可能な状態に移行する機能がなく、センサーの人手によるリセット操作が必要であり (図 4.4)、通信切断の発生が大きなデータロス^{*2}を引き起していた。図 4.2 に示す通信状況では、1 日を通してみた場合、通信切断は 100% 発生し、対策を必要としていた。

■中継器による通信の安定化 上記のように Bluetooth 通信が安定しない状態では Wi-Fi でデータ通信を実装できれば簡単であったが、前述のようにセンサーの機種選択において、監視対象機器内部の設置スペースやケーブルの引き回しも考慮すると Bluetooth 通信の利用が必要であった。そこでセンサーと IoT-GW 間に中継器を設置し、中継器ではセンサーから Bluetooth でデータを受信し、IoT-GW との通信は比較的安定している Wi-Fi

^{*2} 人手によるリセット操作には保守要員の手配、移動が必要であり、現実的な時間では対応できなかった。具体的には 1 日半程度必要であった。

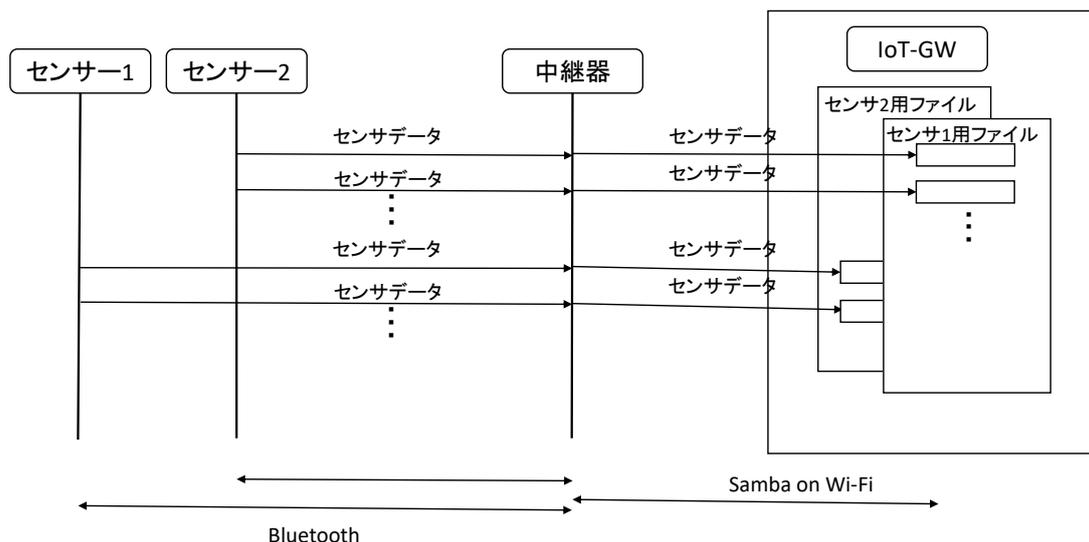


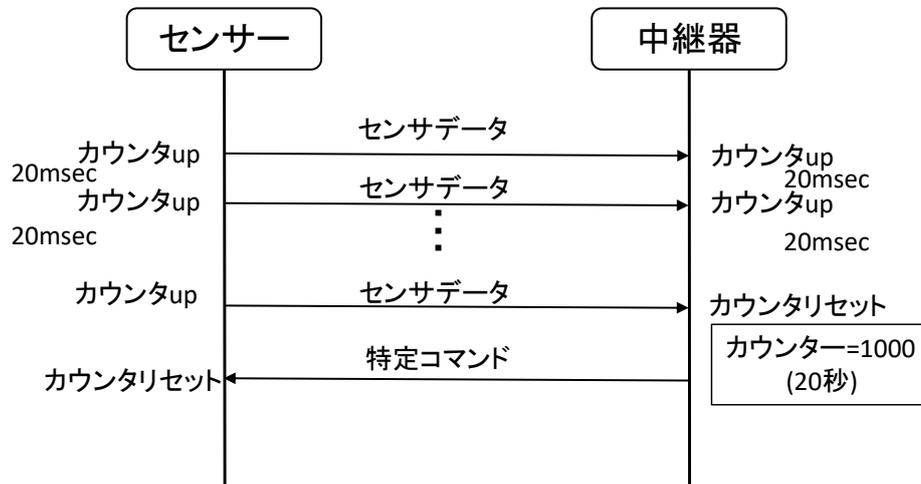
図 4.5 リピーターによる通信の安定化

を用いる方式とした。

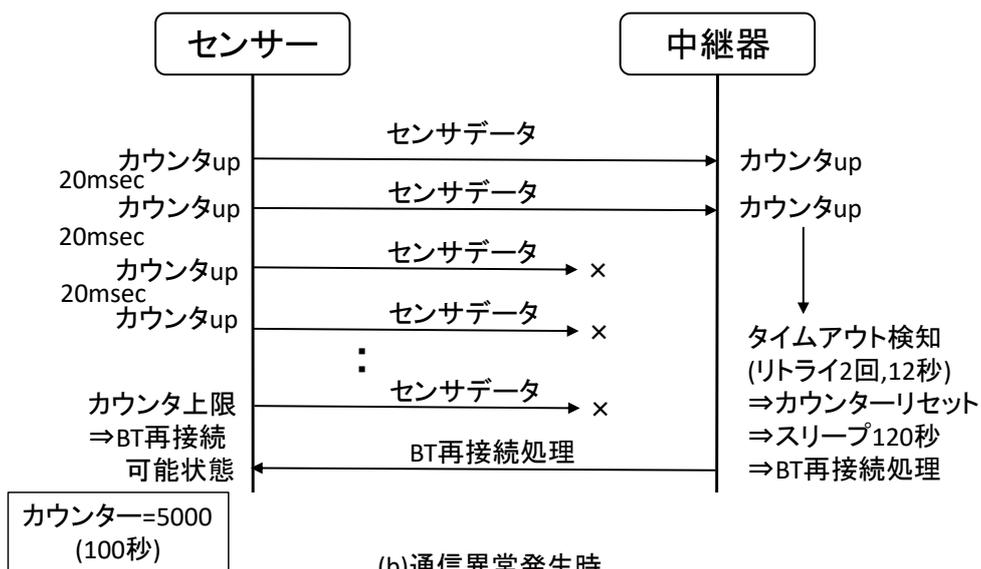
中継器は、センサー本体と数十センチの距離に設置した。図 4.5 に示すように、中継器はセンサーから受信したデータを高速化のため蓄積することなく IoT-GW に転送する事とした。具体的には、中継器は実装が容易な IoT-GW 上の一時蓄積用ファイル (センサー 1 用ファイル, センサー 2 用ファイル) に Samba インタフェースを用いて書き込む方式とした。

■Bluetooth 通信の再接続処理 上述の中継器による対策だけでは Bluetooth 通信が切断された際の問題を解決できない。そこで、図 4.6 に示すように、中継器からセンサー側に定期的に送信する特定コマンドで接続監視を行い、センサー側で一定時間 (センサー側送信カウンターの上限まで) 特定コマンドの受信ができなかった場合、Bluetooth 再接続処理 (以降、BT 再接続処理と略記) に移行するようにした。一方、中継器側ではタイムアウト検知後およそ 120 秒間スリープし、BT 再接続処理を開始する。その上で Bluetooth 通信が切断された際の性能評価を 2 つ実施した。スリープ時間を 120 秒としたのは、通信障害は一定時間継続する傾向にあるためやや長めの値とした。実際に運用した結果、120 秒で異常を見逃した事例はなく、問題なく動作した。^{*3}このため、以降の評価では 120 秒以上のデータ欠損を通信断とみなした。なお、適切なスリープ時間は、工場内の電波状況を分析しきれておらず今後の課題とした。

^{*3} 現実に異常を見逃しトラブルになった事例はなかった。



(a)正常通信時



(b)通信異常発生時

図 4.6 Bluetooth 通信再接続手順

まず、1時間ごとのデータロス率を計算した。データロス率を通信ができなかった時間の割合 $\alpha = \sum_{i=1}^n (T_i)/3600$ (n は当該1時間の通信切断発生回数、 T_i は i 番目の実際の通信切断時間) とした場合の、時間ごとのデータロス率の推移を図 4.7 に示す。データロス率は、時間帯毎に概ね 10%~20% 程度で推移するが、通信状況の悪い一部の装置、時間帯で 20% を超える場合があり、一見すると好ましい結果ではない。

しかしながら、監視ができない時間の長さを計測した場合、結果の解釈は異ってくる。図 4.8 は、各装置特定の3日の通信切断時間 160 秒以内、250 秒以内、360 秒以内の各発生回数を示したものである。BT 再接続処理では、各種センサー情報の取得、サンプリングレートの設定、キャリブレーションなどの初期化処理を実行する。初期化処理は通信状態が回復している場合概ね 30 秒、BT 再接続に要する時間が最大 132 秒 (図 4.6 においてタイムアウト検知 12 秒にスリープ 120 秒を加算) であることから概ね 160 秒以内でデータ通信が再開する。初期化処理の論理上の最大値を適用した場合 250 秒、初期化処理に失敗すると初期化シーケンスの再実行を行うが、現実の観測値から 360 秒を最大値とした。図 4.8 から大部分のケースは 160 秒以内に再接続が実施できており、360 秒を超える長時間の通信切断は生じていないことがわかる。3 章では、6 分間 (=360 秒間) 異常振動が継続したケースを紹介しているが、前記考察から監視は可能である。図 4.7 から 160 秒以内の継続時間の通信障害はデータロス率 (非検出率) が高いケースで 0.3 程度になるが、3 章で述べたように異常診断では、同様の異常が継続して観測されることで異常の兆候を確認することが多いため、1 回のデータロスに遭遇しても実用上問題ない。なお、 n 回にわたる異常検知が同時にデータロスとなる確率は、データロス率 0.3 を用いると、 0.3^n ($n = 2, 3, \dots$) であり、 $n = 2$ の場合でも 0.09 と異常診断には耐えられると判断した。

■通信速度評価 上記の対策を実施した後のセンサーと IoT-GW 間の通信は、3 章で述べたサンプリングレートの必要要件に対し、以下の様になった。

- センサーと中継器間

中継器は 500msec 毎にセンサーからデータ読み込みむこととした。サンプリング周期 50Hz では 1 回の読み込みは 25 レコードとなる。Bluetooth の伝送速度を 1Mbps、1 レコードを 50 バイトとすると、25 レコード転送の遅延は 10msec (転送時間) + 10msec (処理時間、仮定) であり、中継器からの 1 回のデータ読み込み時間は 20msec となるため通信性能には十分な余裕がある。

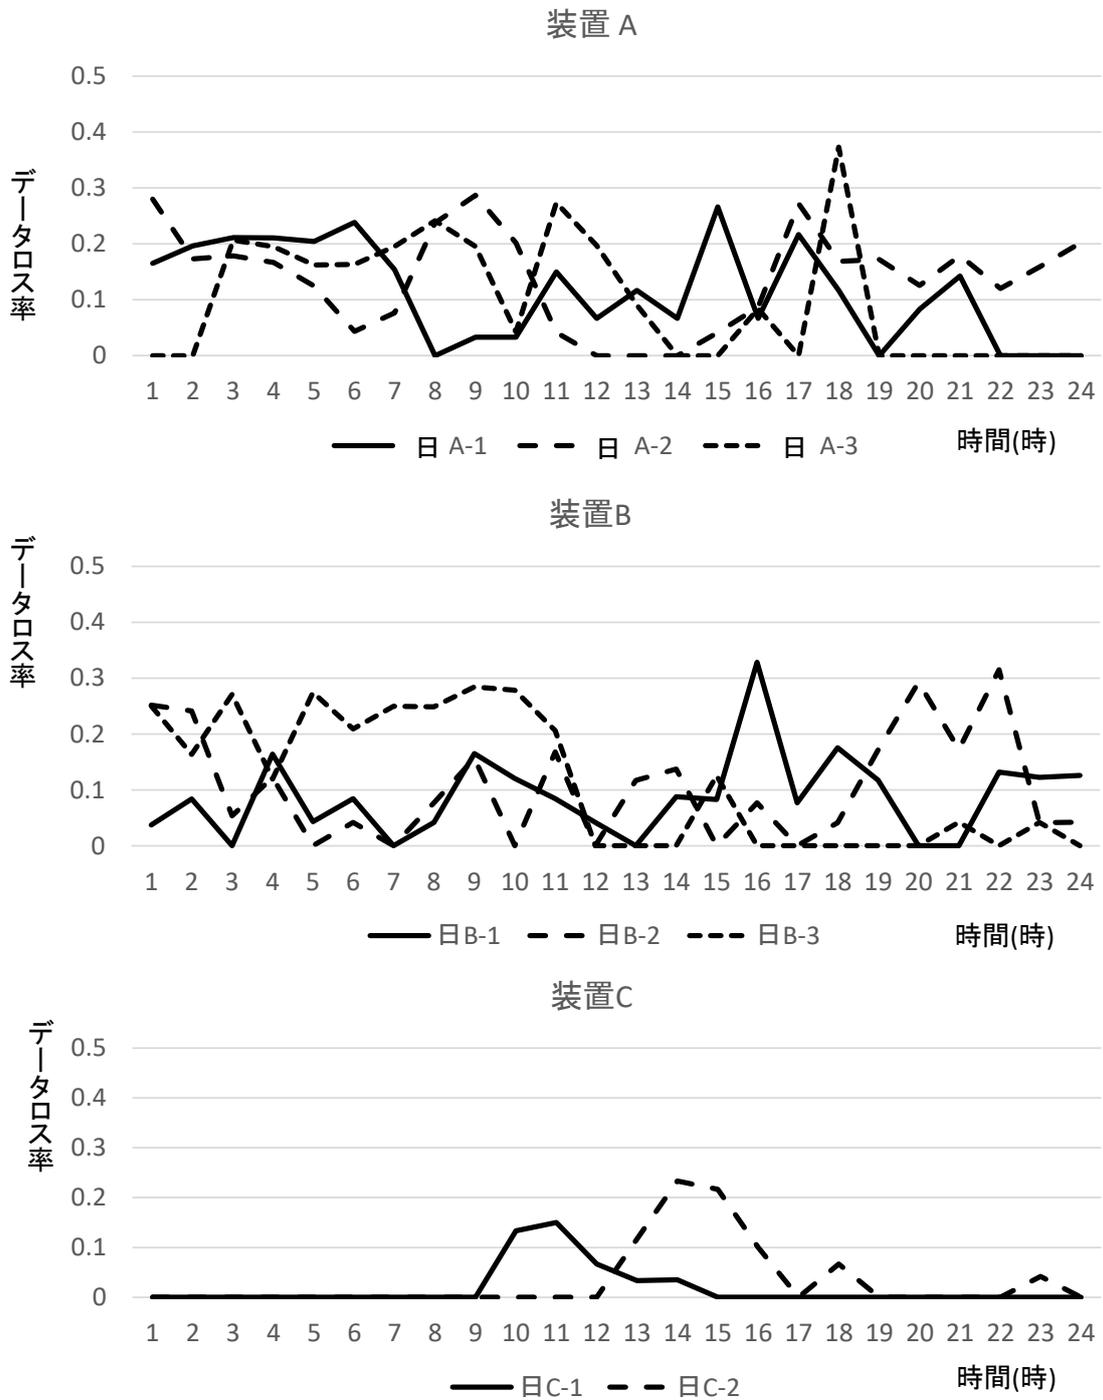


図 4.7 Bluetooth 通信安定化後のデータロス率の推移

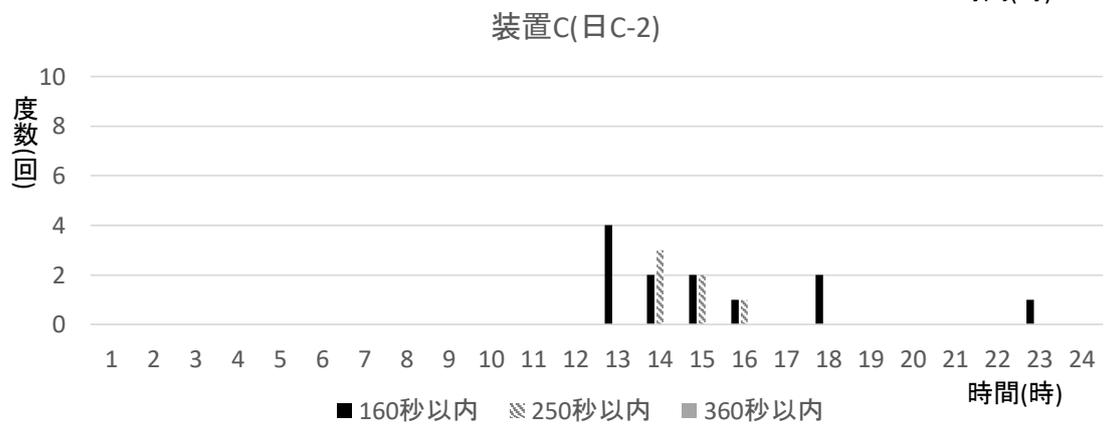
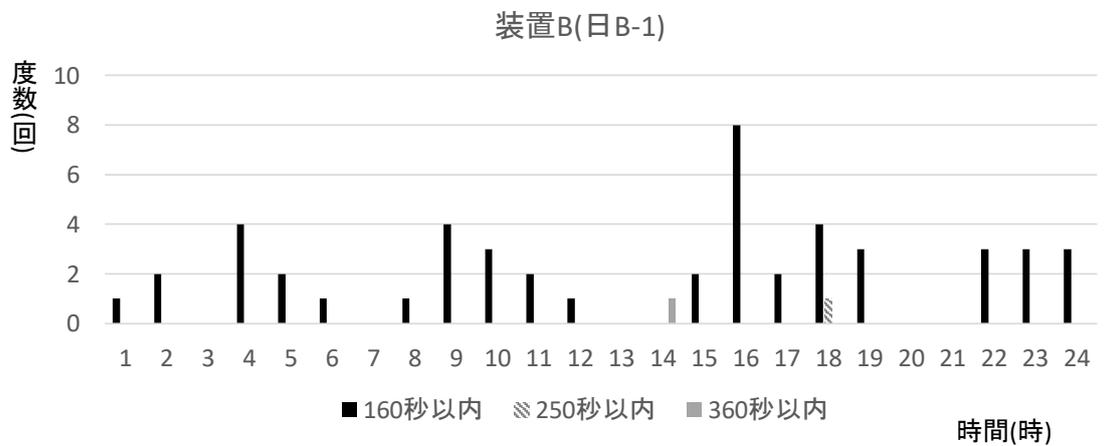
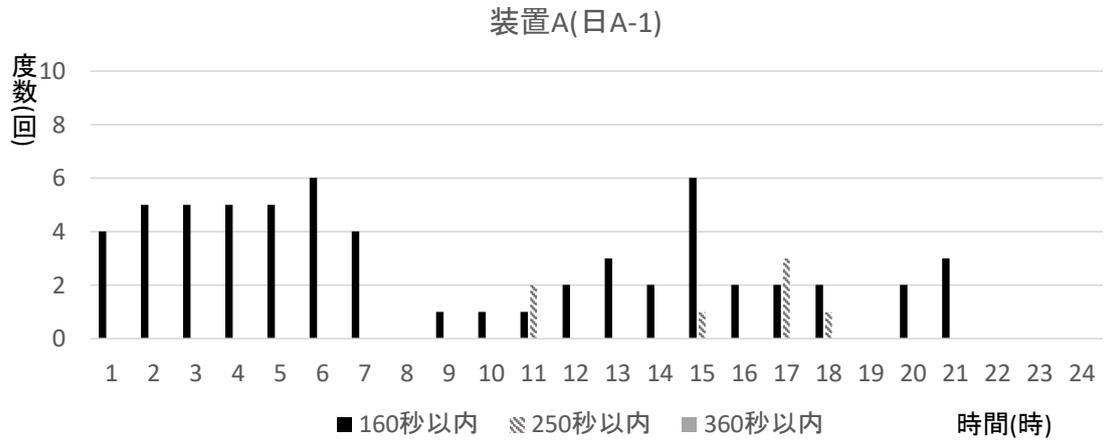


図 4.8 通信切断時間の分布

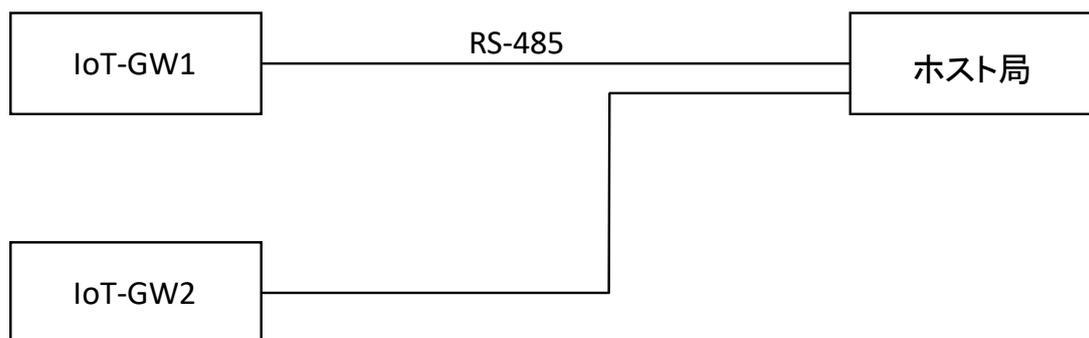


図 4.9 IoT-GW と PC 間の構成

- 中継器と IoT-GW 間

中継器は 500msec 毎にセンサーから 25 レコードのデータを読み込むとこれらのレコードを samba インタフェースで IoT-GW 上のファイルにデータを書き込む。500msec 毎に発生する 25 レコードのファイル書き出し遅延は実測値で 20msec(ファイルオープン/クローズ処理除外)であり、通信性能には十分な余裕がある。

上記議論から 25 レコードのセンサーから IoT-GW までのデータ転送の遅延時間は、(1) センサーと中継器間転送時間は中継器での待ち時間に含まれ 500msec、(2) 中継器での受信処理時間 10msec、(3) 中継器から IoT-GW へのファイル書き出し時間 20msec の合計でおよそ 530msec である。

IoT-GW と PC 間の通信方式

■通信方式 IoT-GW と PC 間は、建屋を跨いで約 1km の距離があり、また遮蔽物も多いことから Wi-Fi もしくは有線 LAN を新たに設置することは高コストになり現実的ではない。既存の電力ケーブルが利用できる PLC(Power Line Communication)[77] の適用も候補になるが、PLC の仕様上配電盤を通過できない制約があるため実環境では利用できないことが分かった。

このため、電氣的ノイズに強く低コストで実現可能な通信手段として RS485(2 線式、半二重) を選択し、配線は既設のケーブル架を利用した。幸い IoT-GW と PC 間のケーブル架は余裕があり配線に大きな問題は生じなかった。そこで RS485 は複数の IoT-GW からの同時通信性能を確保するため、図 4.9 に示すように複数の IoT-GW をホスト局 (PC) の複数のポートに接続する構成とした。

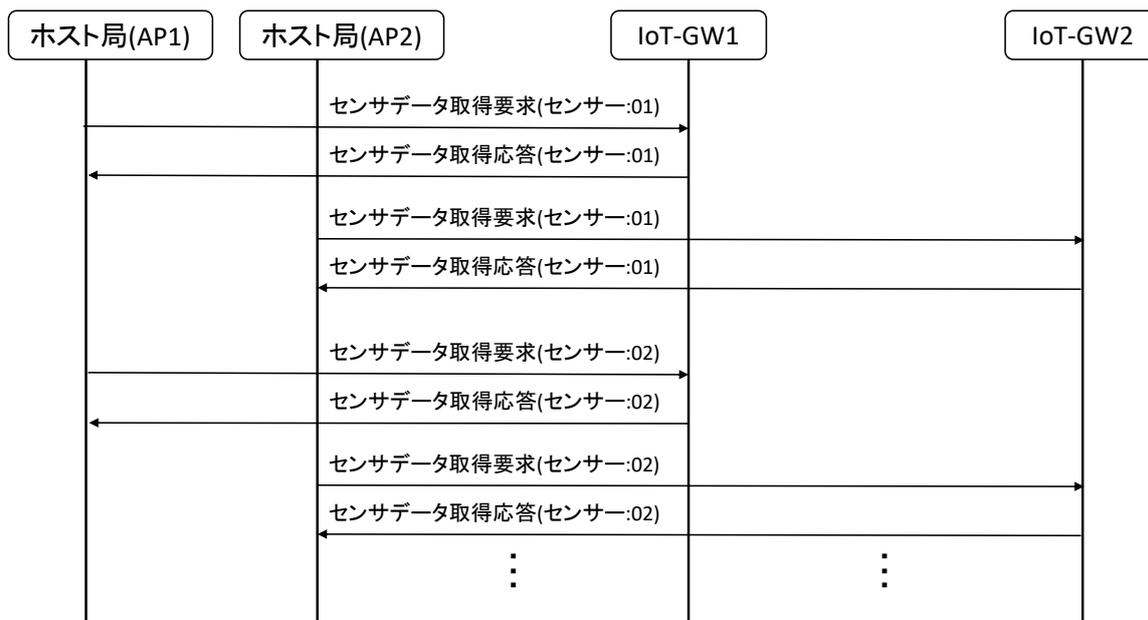


図 4.10 IoT-GW と PC 間の通信手順

■**転送速度評価** IoT-GW と PC 間の通信シーケンスを図 4.10 に示す。IoT-GW と PC 間は約 1km であり、この場合の通信速度は 115,200bps である。RS485 は距離によって通信速度が変化し、10m までは 35Mbps、最大長 1200m で 115,200bps である [78][79]。RS485 による有線での通信は無線と異りカタログ仕様どおりの設計で問題を起こさなかった。加速度センサーのデータは、3 章で示した通り 1 センサーあたり 1 秒間に 50 レコード (1 レコード 3 軸で 50 バイト長) が IoT-GW に格納される。1 装置あたり 5 センサーとし、PC 側は 30 秒周期で IoT-GW からデータ収集を実施すると、30 秒間では 7500 レコードが IoT-GW に蓄積され、このデータ転送時間は 5.2 秒である。

■**通信障害からの回復** IoT-GW と PC 間の通信障害対応のため、IoT-GW 上のセンサーデータは、PC (ホスト局) 側から回収があるまで IoT-GW 上にデータを保持することとした。実環境では、通信路上のノイズに起因する BCC エラーや人為的問題による制御室 PC の停止が発生した経験から、一定量を IoT-GW 上に保持することは通信障害によるデータロスを防止する観点から重要な機能である。

通常時は IoT-GW には PC(ホスト局) からのポーリング間隔 30 秒間のデータを蓄積する。30 秒間のデータ蓄積量は $50\text{B}/\text{データ} \times 50 \text{データ}/\text{秒} \times 5 \text{センサー} \times 30 \text{秒} = 375\text{KB}$ である。IoT-GW と PC 間の通信障害時には通信が復旧するまでの間 IoT-GW でデータ

を蓄積する。従って1時間の通信障害では45.0MB、24時間の通信障害では1,079MBのデータがIoT-GW上に蓄積される。

1時間の通信障害からの回復では、蓄積された45.0MBのデータ転送に3130秒、転送時間中の新たなセンサーデータの蓄積を考慮すると、3432秒で遅延を解消できる。24時間の通信障害からの回復では、蓄積された1,079MBのデータ転送だけで20.8時間を要することから自動回復は現実的ではない。このようなケースでは、現場でIoT-GWから直接データを吸い上げる等の人手操作が必要であるが、現実には稀な事象であり運用の阻害要因にはなっていない。

また、IoT-GWで蓄積可能なデータ量はディスク容量に応じて決まるが、産業用の小型機とは言え近年の計算機の記憶容量から考えて十分小さい。

4.4 開発システムの特徴

表4.2に開発システムの特徴をまとめる。表4.2では、プラント監視データ収集システムにおける一般的考慮事項と本システム特有の要件、適用した方式を示す。3章では、必要なデータ収集能力を以下のように議論した。

- データ収集能力

収集データ項目と監視箇所の決定には、故障による運用影響と交換部品の適切な交換時期の2点に着目した。3章で述べた故障診断要求事項から駆動部であるベアリング、モーターにセンサーを設置して振動データ、温度データを収集することとした。また、データ収集速度は、3章で示した故障診断要求事項に基づき収集頻度(サンプリングレート)を設定した。

本研究で議論した上記データ収集能力実現の諸課題と解決策を以下に示す。

- 安定的な通信の確保

上記データ収集能力をを実現するためのセンサーとIoT-GW間、IoT-GWとPC間の通信方式を性能や安定性の観点から議論した。性能評価を実施し、電磁波等のノイズ影響を考慮した通信の自動回復方式を示した。

- 全体システム構成/IoT機器の選定と設置

収集データの集約方法では、外部からの監視が必要であったためクラウドへの集

表 4.2 開発システムの要求事項と実現方式

要件	一般的考慮事項	本システム特有の要件	適用方式
データ収集能力*	<ul style="list-style-type: none"> ・監視の目的 ・故障診断の詳細 	<ul style="list-style-type: none"> ・駆動部の故障検知 ・交換部品の状態監視 	<ul style="list-style-type: none"> ・モーター、ベアリングにて 振動データ、温度データを収集 ・サンプリングレート (振動データ: 50Hz)
安定的な通信の確保	<ul style="list-style-type: none"> ・通信性能 ・安定性 	<ul style="list-style-type: none"> ・必要なデータ収集機能の実現 ・ノイズ影響の解決 	<ul style="list-style-type: none"> ・性能評価 ・データ通信自動復旧処理
全体システム構成/IoT機器の選定と設置	<ul style="list-style-type: none"> ・データ集約方法 ・構築容易化 ・通信方式 ・セキュリティ 	<ul style="list-style-type: none"> ・クラウドへのデータ集約 ・外部IoTデバイスの設置 ・既存の機器への影響排除 	<ul style="list-style-type: none"> ・システム構成: <ul style="list-style-type: none"> -センサー ⇒ IoT-GW (無線) -IoT-GW⇒PC(RS-485) -PC ⇒ クラウド (LTE) ・適切な機器の設置、ケーブル敷設

*3章で議論した故障診断要求事項

約を選択した。IoT 機器の導入容易性、耐久性、コストを考慮、センサーデータは IoT-GW で無線通信により収集し、セキュリティ対策で有利な IoT-GW から PC に一旦集約してからクラウドに転送する方式とした。センサーの仕様および必要な通信帯域は 3 章で示した故障診断要求事項に基づく収集データ速度から決定、機種選定を行った。また、既存設備への影響がないように、IoT 機器の設置、ケーブルの敷設を適切に実施した。

4.5 むすび

本研究ではプラント監視システムにおけるデータ収集システムの構築に焦点を当てて、予知保全のためのデータ分析に必要十分なデータ量を安定的に収集するための課題と解決策を提案した。具体的には、コンピュータの運用に適さない環境でのセンサーや IoT-GW の選定と設置方法を提案し、実証実験を通してこれらの効果を検証した。特にノイズ影響に対しては、発生を前提にデータ通信の自動回復処理方式を提案、通信のリセットタイミングの調整が重要であることを示した。具体的には、センサーと IoT-GW の間に中継器を設けセンサーとの Bluetooth 通信を送信出力の大きい Wi-Fi に変換するとともに、中継器からセンサー側 (Bluetooth 通信) に定期的に送信する特定コマンドで接続監視を行い、センサー側で一定時間特定コマンドの受信ができなかった場合、Bluetooth 再接続処理に

移行するようにした。これにより、通信切断時の自動回復を実現した。

第5章

プラント監視方式の空調機システムへの応用に関する研究

5.1 はじめに

本研究では、3章、4章で議論した飼料工場を例としたプラント監視開発プロセスを空調機設備の監視システムの開発に適用した。表 2.1 研究分野#5,#7で述べたように機械装置等の異常検知は広く研究されている。これらの研究では、正確なデータが利用可能であるとの仮定がおかれているケースが多く、本研究の低コストセンサーの使用によって引き起こされるノイズの影響などは考慮されていない。さらに、空調機固有の気候条件による機械の運転状態の変化に着目した精度向上は考慮されていない。また、表 2.1 研究分野#7に示すように空調機を対象とした研究や監視システムの開発事例があるが、運転の最適化など電力消費に着目したものが多くまた監視システムは、主として大規模システムを対象としている。

本研究では、季節性と気候変動に焦点を当て、特に空調機の異常検出モデルの精度を向上させる方法を提案する。さらに、中小規模の施設のコスト問題にも対応、異常診断に必要なデータを取得するために、適切な場所に低コストのIoTセンサーを設置することについても議論する。

5.2 空調機とIoTセンサーの構成

図 5.1 は、空調機とIoTセンサーの設置構成を示す。対象となる空調機は、オフィス用天井カセットタイプで、室内機と室外機で構成される。

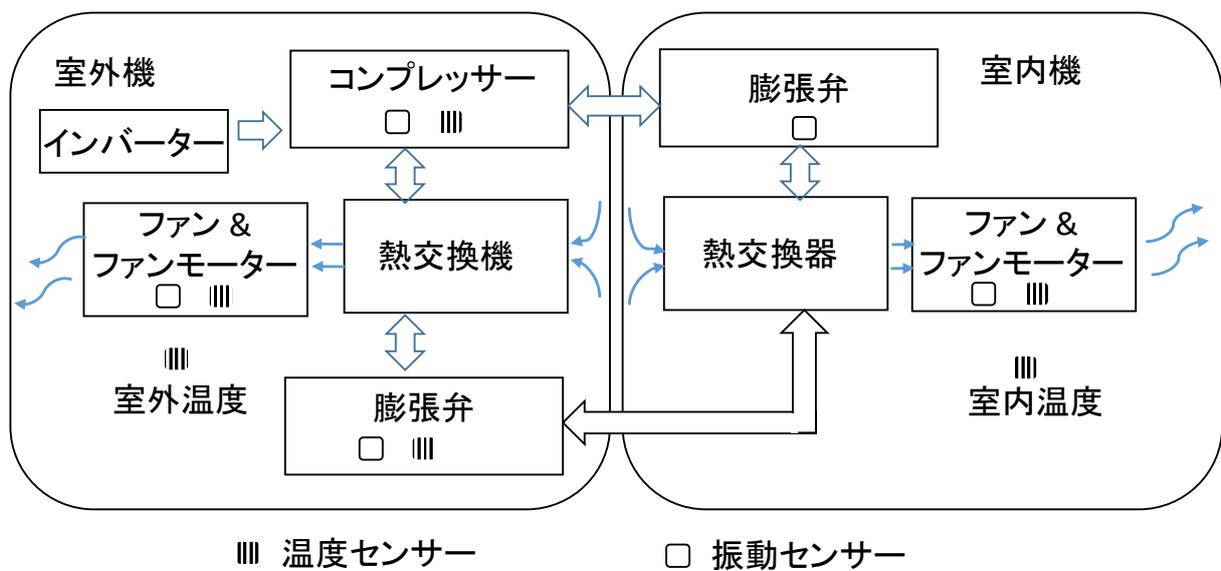


図 5.1 空調機とセンサー設置位置

動力源であるコンプレッサーは、冷媒を圧縮して温度と圧力を上昇させる。膨張弁は、冷媒を狭い隙間に通して温度と圧力を下げ、流量と温度を自動的に調整する。膨張弁の室内機側は冷房時に動作し、室外機側は暖房時に動作する。ファンモーターは屋内/屋外の空気を動かし、熱交換器は、冷媒と屋内/屋外の空気の間で熱を交換する。温度制御機構は、インバーターを使用してコンプレッサーの動作を制御する。

空調機の異常の半数以上は、フィルターや熱交換器の目詰まりによる風量の減少が原因である。このような事象を早期に発見するために、空調機の主要部品である、コンプレッサー、屋外ファンモーター、膨張弁、屋内ファンモーターに振動センサーと温度センサーを設置した。振動データを主たる情報として使用し、補足情報として温度データも使用した。振動データは、3軸振動センサー(X軸、Y軸、およびZ軸)を使用して収集した。テスト目的で、通常タイプのセンサーに加えて、通常タイプのセンサーよりもサンプリングレートが低く、データ収集の安定性が低いローコストタイプの振動センサーも設置した。

5.3 異常検知システム

5.3.1 データ収集システム

3章、4章で議論したようにIoT設備の計算能力が限られていることを考慮し、IoTセンサーで収集したデータはIoT-GWを介してクラウドに転送することとした。図5.2にデータ収集システムの構成を示す。各センサーから収集されたデータはIoT-GWに集約され、クラウドを経由してデータ分析サーバーに転送する。クラウドでは、センサーデータをリアルタイムで監視し、異常検出のためのデータ分析は、データ分析サーバーで実行した。

表5.1に各センサーのデータ収集条件を示す。サンプリングレートは、センサー仕様にに基づき、通常タイプの振動センサーでは50Hzに、ローコストタイプのセンサーでは10Hzにそれぞれ設定した。通信方法は、デバイスの仕様にに基づき、温度センサーはWi-Fi、通常タイプの振動センサーはBluetooth、ローコストタイプの振動センサーはIEEE802.15.4とした。

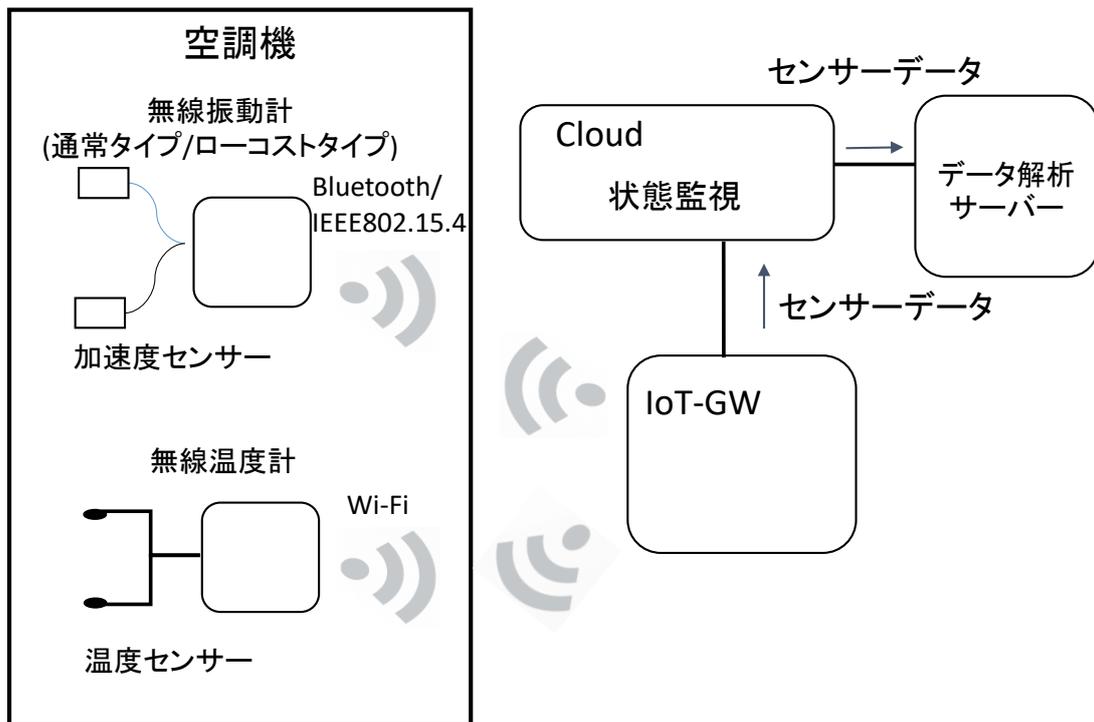


図 5.2 データ収集システム

表 5.1 データ収集条件

#	センサータイプ	計測値(単位)	通信	サンプリングレート
1	通常タイプ 振動センサー	加速度(m/s ²) (3軸)	Bluetooth	50Hz
2	ローコストタイプ 振動センサー	加速度(m/s ²) (3軸)	IEEE802.15.4	10Hz
3	温度センサー	セ氏(°C)	WiFi	0.1Hz

5.3.2 データ解析手順

データ分析では、Convolutional Autoencoder (CAE) [93] と Isolation Forest [94] の2方式を使用してデータ解析を実行し、結果の信頼性を向上させた。

Convolutional Autoencoder:

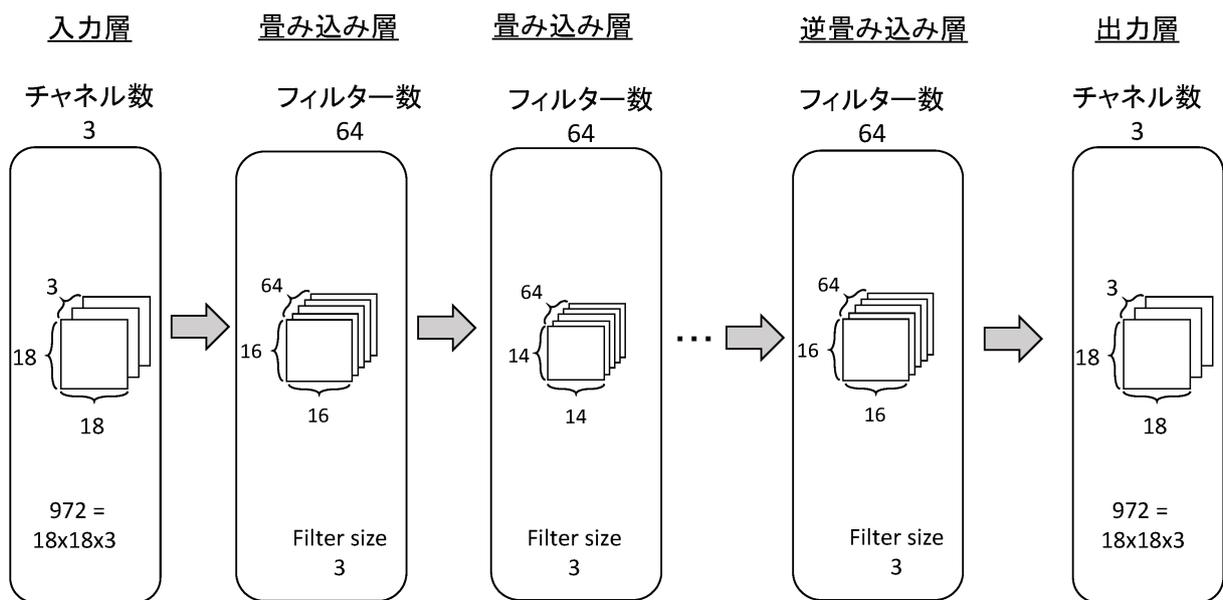
Autoencoder [46] は、通常の動作状態に基づくモデルを作成するニューラルネットワークの一種である。CAE は、データの畳み込み層と逆畳み込み層を持つ Autoencoder の一種である (図 5.3 を参照)。CAE 入力として、3 軸振動データのそれぞれを高速フーリエ変換 (FFT) で処理した 324 ポイントのパワースペクトルを使用した。次に、予備実験に基づいて、フィルターのサイズと数を決定した。入力データが通常の動作状態で取得された場合、出力と入力の差は小さく、特定のしきい値を設定し、違いを比較することにより異常状態を検出できる。予測データ x と観測データ x' から異常度スコア E は、次のように平均二乗誤差として定義した。

$$E = \frac{\sum_{n=1}^N (\|x_n - x'_n\|)^2}{N}$$

ここで、 x の次元 N は 972 である。

Isolation Forest:

Isolation Forest は、複数の決定木に対応するリーフノードに到達する距離から異常度スコアを計算する方法である。ルートからリーフノードまでの平均距離が異常スコアを表す。このため、異常な外れ値のデータは、各ツリーの対応するリーフノードに早期に分割される可能性が高くなるため、前記距離が小さい場合は、異常度スコアが高いと判断できる。異常度スコアは、 $2^{-E(h(x))/c(n)} - \text{offset}$ と表せる。ここで、 $h(x)$ は、決定木 x の入力のリーフに到達する距離である。 $E(h(x))$ は、複数のツリーの $h(x)$ の平均であり、 $c(n)$ は決定木の平均深度である。「オフセット」は、異常率から正常/異常の標準値を調整するために使用される。以上のことから、異常度スコアが 0 以下の場合に異常と判断することができる。Isolation Forest への入力値は、3 軸振動データの FFT で処理した 324 ポイントのパワースペクトルを使用した。



畳み込み層	逆畳み込み層	各層のフィルター数
7層	7層	[64,64,128,128,256,256,256]

図 5.3 Convolutional Autoencoder の構成

5.3.3 異常検知用学習モデルの作成

異常検出の学習モデルは、異常度スコアのしきい値を使用して、正常な状態と異常な状態を区別できる必要がある。本研究では、以下の手順で連続運転データと異常データから学習モデルの作成を試みた。

- 初期学習モデルは、連続運転の最初の3日間のデータを使用して作成する。
- 異常時に取得したデータに基づいて、適切な異常検出しきい値を設定する。
- 日々の監視を通して、学習モデルを更新し、必要に応じてしきい値も見直す。

空調機の動作は季節によって異なるため、夏と冬では異なるモデルを使用する（詳細は、5.4.3節を参照）。

5.4 実験結果

5.4.1 モデル調整プロセス

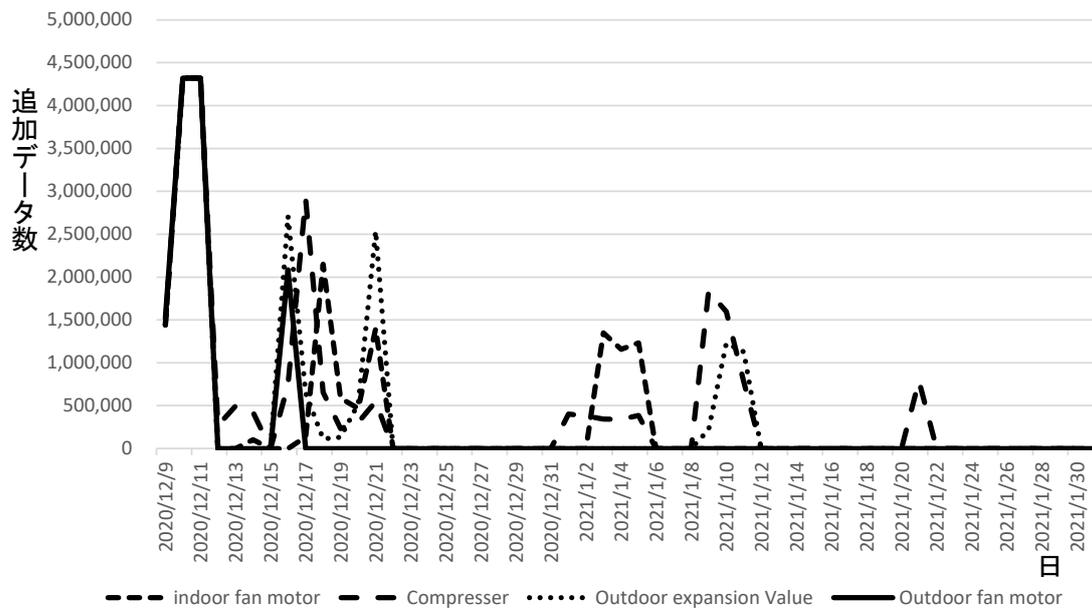
表 5.2 に冬の2ヶ月間の通常運転状態のデータ収集および3日間の障害試験（夏1日、冬2日）のデータ収集を行った実証実験の概要を示す。これらの3日間の障害試験では、吸入ポートの閉鎖率を変更することにより、風量をそれぞれ40%、50%、および80%減少させた。動作モードは、夏は冷房、冬は暖房とした。図 5.4 (a) は、学習モデルの更新に使用した各センサーのデータ数を示す。学習モデルは、異常度スコアがしきい値を超える範囲のデータで更新した。最初の数日に基づいて生成された初期モデルとしきい値は適切でなかったため、以降の日のデータを使用してそれらを調整する必要があった。図 5.4 (b) は、対応する外気温の変化を示す。図 5.4 (a) と (b) を比較すると、外気温が大幅に変化したときにモデルとしきい値が更新されたことが分かる。以上より、空調機の運転状況は気候条件によって大きく変化することが分かった。

5.4.2 センサー位置の評価

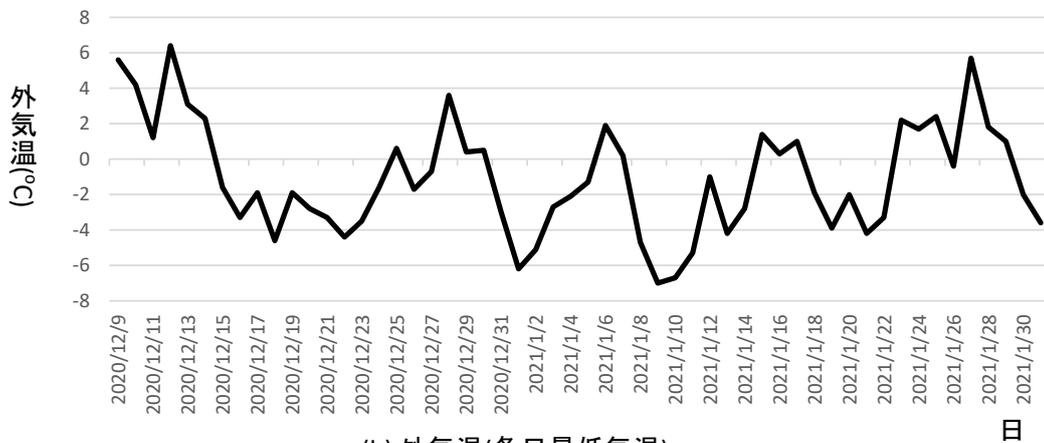
次に、異常の原因（室内機の故障か室外機の故障か）を検出できるセンサーの設置位置を明確にすることを試みた。表 5.3 は、異常を検出できた（または検出できなかった）センサーの位置を示す。この表では、各センサー位置の項目は、それぞれ左から第1回、第2

表 5.2 テスト項目とテスト条件

#	試験形態	日付	テスト状況
1	第1回障害試験	2020/8/21	室内機/室外機の吸入ポート閉鎖による風量の減少 (冷房運転:27℃設定, 急風)
2	第2回障害試験	2020/12/15	室内機/室外機の吸入ポート閉鎖による風量の減少 (暖房運転:20℃設定, 急風)
3	第3回障害試験	2021/1/19	同上
4	連続運転試験	2020/12/9 ~ 2021/1/31	24時間連続運転(障害試験日は除く) (暖房運転:20℃設定, 急風)



(a) 追加データ数



(b) 外気温(各日最低気温)

図 5.4 学習データの追加数と外気温の推移の関係

表 5.3 障害試験の結果

#	障害箇所	操作	振動データ解析結果(CAE/Isolation forest)											
			センサー位置											
			コンプレッサー			ファンモーター (室外機)			膨張弁 (室内機/室外機)			ファンモーター (室内機)		
1	室内機障害	40% 閉鎖	-	N	N	-	N	N	-	A	N	-	A	A
2		50% 閉鎖	N	N	N	N	N	N	A	A	N	A	A	A
3		80% 閉鎖	A	N	N	N	N	N	A	A	N	N	A	A
4	室外機障害	40% 閉鎖	-	N	N	-	A	N	-	N	N	-	N	N
5		50% 閉鎖	A	N	N	A	A	A	A	N	N	N	N	N
6		80% 閉鎖	A	A	N	A	A	A	A	N	N	N	N	N

A: 異常検知 N: 異常非検知 -: 試験未実施
 表記: 第1回(冷房)/第2回(暖房)/第3回(暖房)

回、第3回の障害試験の結果を示す。空調機の運転パターン（冷暖房など）は季節によって異なるため、異常を正確に検出できるセンサーの位置は異なる。コンプレッサーと膨張弁は、夏季の室外機側故障と室内機側故障を検出できるが、冬には検出できない。一方、季節に関係なく、室外機側の故障は室外ファンモーターで、室内機側の故障は室内ファンモーターで検出できる。図 5.5 に第2回の障害試験における室外機ファンモーターの解析結果を示す。障害が発生したときに異常度スコアがしきい値を超え、CAE と IsolationForest の両方で異常を検出した。正常な状態と異常な状態を区別できるように、CAE ではしきい値を 400 に設定した。IsolationForest では、5.3.2 節で示したように異常度スコアが 0 以下を異常と判断する。図 5.6 は、第3回の障害試験の結果を示す。第2回障害試験と同様の結果を得、CAE のしきい値は 400 である。

このように、振動センサーを適切なセンサー位置に設置すれば、異常検出ルールを作成できることが分かった。一方、図 5.7 に示すように、温度センサーでは異常を検出できない。図 5.4 に示すように、気候変動を確認するには温度データが必要であるが、異常検知には効果がないことが分かった。

5.4.3 季節性の評価

本節では、空調機の動作パターンに対する季節性の影響を分析する。CAE と IsolationForest の分析結果はほぼ同等であるため、簡略化のため以降では CAE の結果のみを示す。

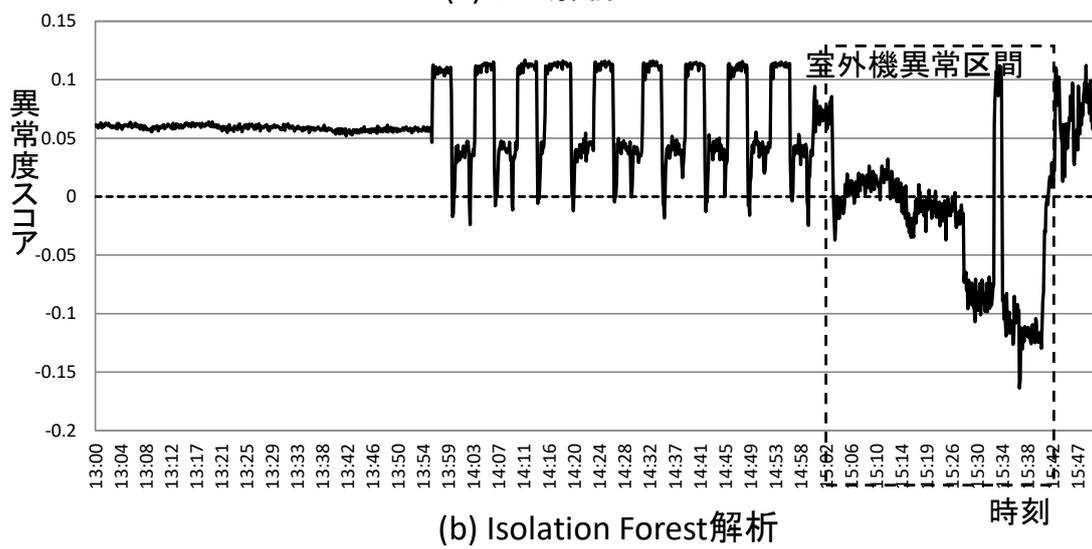
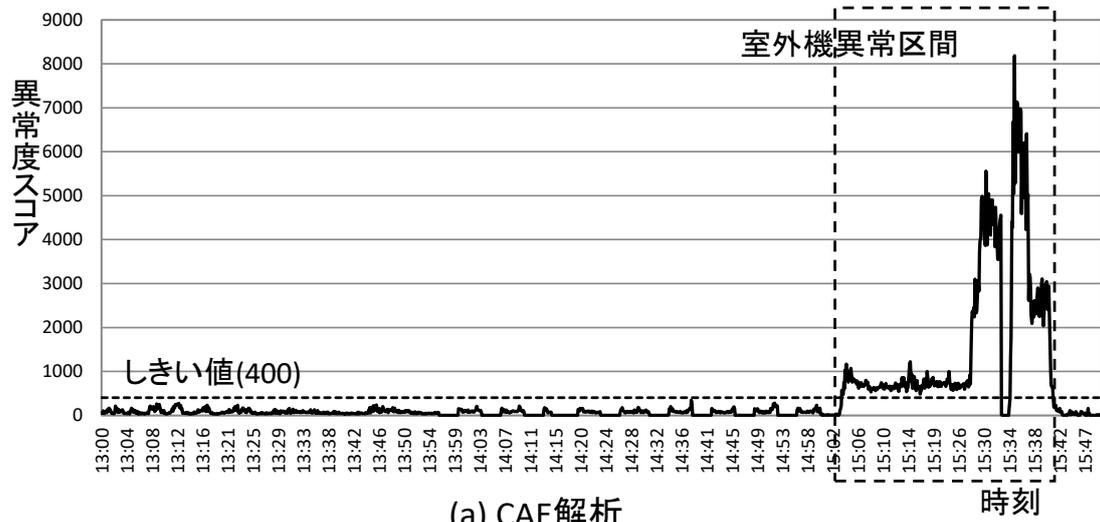
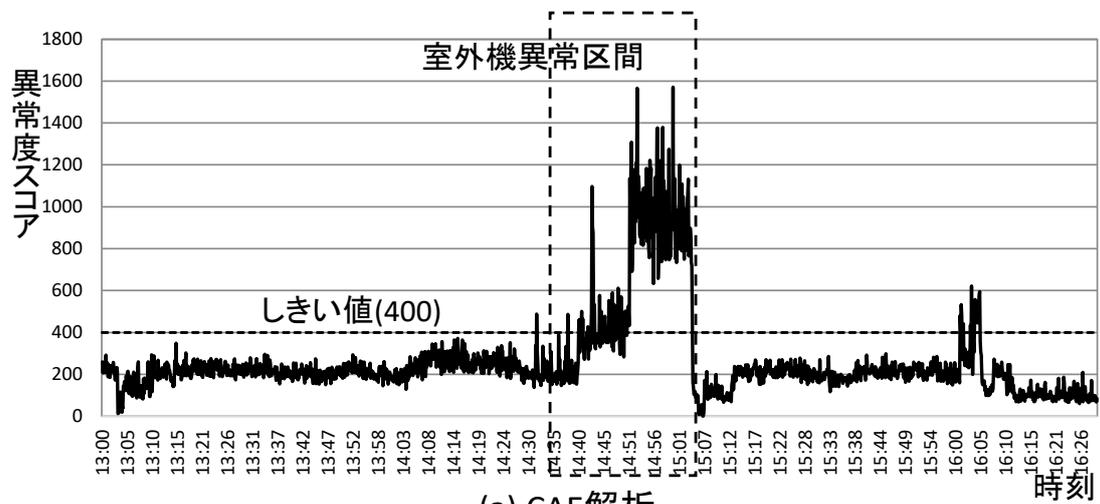
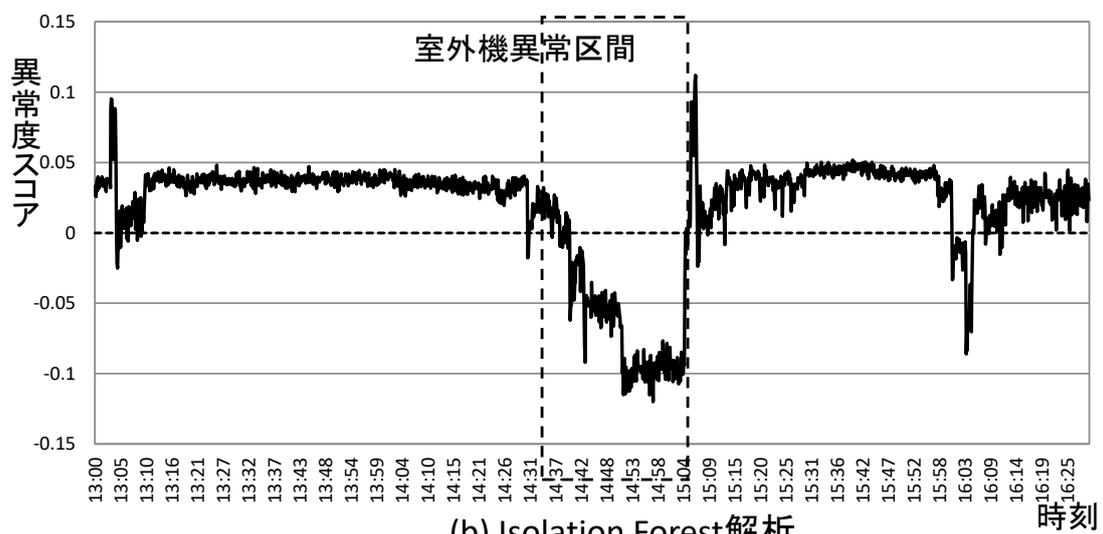


図 5.5 第 2 回障害試験における室外機ファンモータデータ解析結果

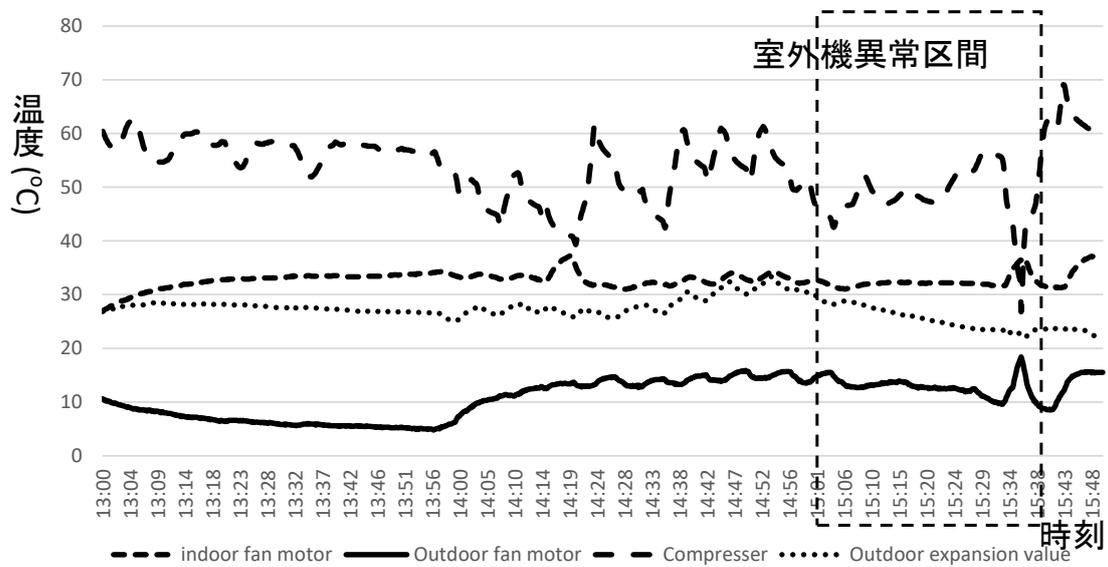


(a) CAE解析

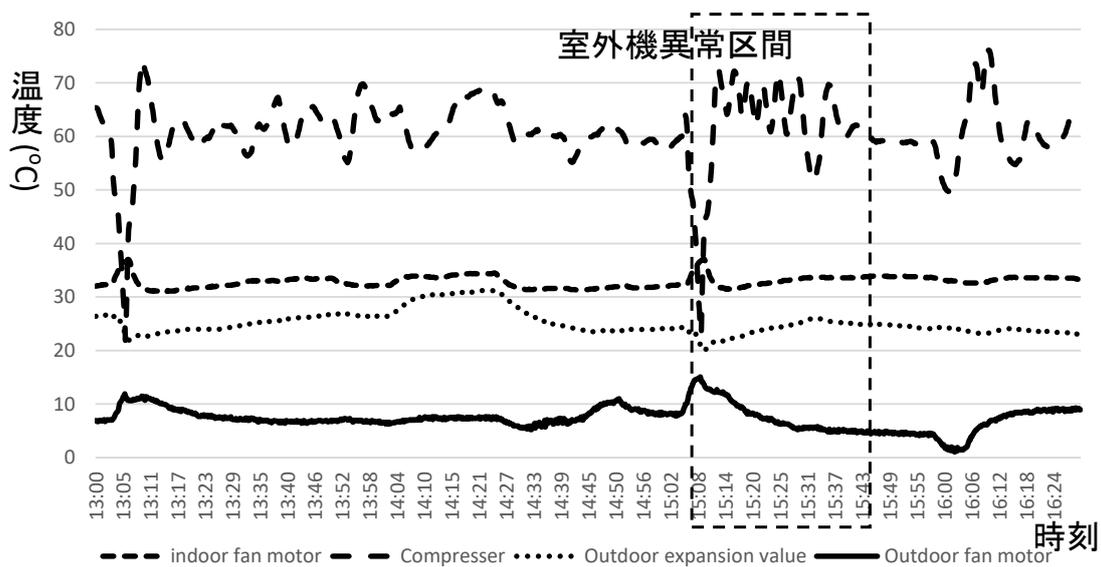


(b) Isolation Forest解析

図 5.6 第 3 回障害試験における室外機ファンモーターデータ解析結果



(a) 温度推移 (第2回障害試験)



(b) 温度推移 (第3回障害試験)

図 5.7 第 2 回および第 3 回障害試験における温度推移

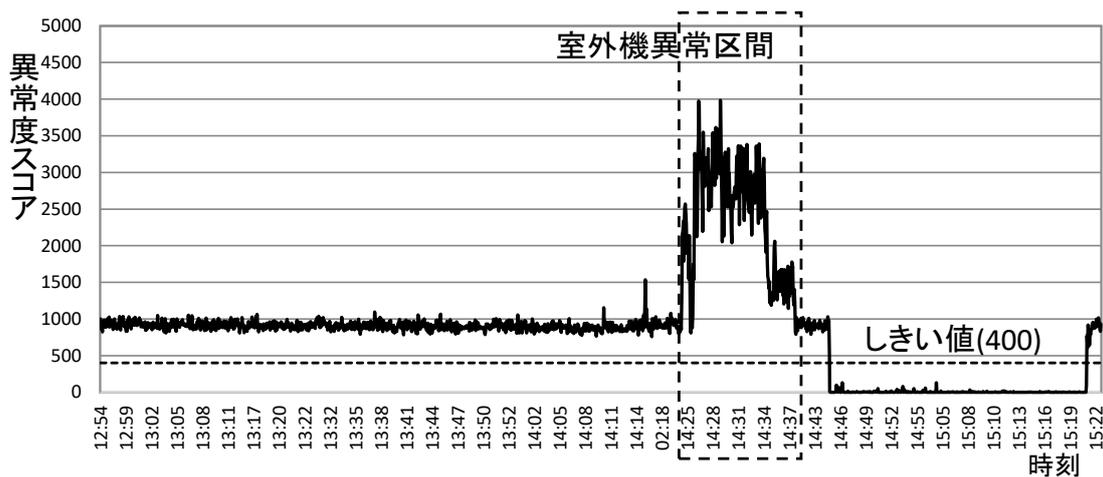


図 5.8 第 1 回障害試験における室外機ファンモーターデータ解析結果

し、IsolationForest の結果は省略する。図 5.8 は、2 か月間の冬季データ（12 月のデータと 1 月のデータ）の学習モデルを使用した第 1 回障害試験（夏季）での室外機ファンモーターデータ分析の結果を示している。通常運転中の異常度スコアは、しきい値 400 に対して大幅に増加していることから夏のデータは冬のデータとは大きく異なることが分かる（図 5.5 および図 5.6 を参照）。以上の事実から、季節性や気候が空調機の運転に与える影響を考慮した異常検知精度向上手法を提案する。提案手法では、季節ごとに異なるモデルを使用する。提案手法の異常検知精度を検証するために、最初に、個々の月のデータで学習したモデルの異常検知精度を、複数の月のデータで学習した統合モデルと比較した。表 5.4 と表 5.5 に比較の結果を示す。これらの表は、正常区間と異常区間の間の異常度スコアの分離性能を示す。分離性能は、試験期間中の異常区間の最大値と正常区間の最大値の比で、最大値は異常度スコアの移動平均から計算したものである。ここで、表 5.4 で 12 月のデータモデル、8 月のデータモデル、および 12 月と 8 月の統合データモデルによる各障害試験の結果を比較する。さらに、表 5.5 で 12 月のデータモデル、1 月のデータモデル、および 12 月と 1 月の統合データモデルによる各障害試験の結果を比較する。これらの表に示したように、統合モデルを使用した場合は分離性能が小さいため、正常・異常の分離は困難である。表の斜線部分は、正常時と異常時のスコアの比率が比較的小さく分離が難しい部分を示している。

次に、観測データの異常度スコアが最も低いモデルを採用する方法をテストした。図 5.9 に各試験における提案手法の室外機ファンモーターデータの解析結果を示す。さらに、図 5.10 に 8 月/12 月の統合データモデルの室外機ファンモーターの解析結果を示す。

表 5.4 異常検知精度の比較 (8月/12月)

センサー	障害箇所	予測: 8月障害試験データ (8/21/2020)		予測: 12月障害試験データ (12/15/2020)	
		8月データ モデル	8月/12月統合 データモデル	12月データ モデル	8月/12月統合 データモデル
ファンモーター(室内機)	室内機障害	6.39	6.09	1.72	1.85
ファンモーター(室外機)	室外機障害	30.12	17.38	17.59	17.38

表 5.5 異常検知精度の比較 (12月/1月)

センサー	障害箇所	予測: 12月障害試験データ (12/15/2020)		予測: 1月障害試験データ (1/19/2021)	
		12月データ モデル	12月/1月統合 データモデル	1月データ モデル	12月/1月統合 データモデル
ファンモーター(室内機)	室内機障害	5.72	1.97	8.51	4.07
ファンモーター(室外機)	室外機障害	54.1	42.1	18.23	4.36

表 5.6 異常検知精度の比較

障害試験	分離性能		
	提案方式 (3モデル使用)	12月-1月 統合モデル	8月-12月 統合モデル
第1回障害試験	27.0	3.4	17.38
第2回障害試験	70.0	42.1	17.38
第3回障害試験	14.7	4.3	3.94

図 5.10 では、ハッチングされた部分がしきい値を超えており、図 5.9 では、提案方式を用いることでしきい値 250 で正常と異常を区別できることが分かる。統合データモデルを使用すると図 5.10 に示すように分離性能が低下する。

表 5.6 に示すように、提案方式 (単月のデータモデル) の分離性能は、統合データモデルの分離性能よりも優れている (表の太線の囲み箇所を参照)。*1

5.4.4 ローコストセンサーの評価

コストの問題に対処するために、ローコストタイプの振動センサーと通常タイプの振動センサーを比較する。表 5.1 に示すように、ローコストタイプの最大サンプリングレートは 10Hz である。図 5.11 にローコストタイプセンサーの 1 日あたりのデータ損失数を示す。データ損失の数は、指定されたデータ収集間隔 α (サンプリングレートにより決定される) 以内にデータを受信できなかった 1 日当たりの回数とする。ローコストセンサーによるデータ損失の数は、受信する必要のあるデータ数と比較した場合、2% から 20% で、通常タイプセンサー (1% 以下) よりも大きい。

図 5.12 に通常タイプセンサーとローコストタイプセンサーの CAE 解析結果を比較する。ローコストタイプセンサーでは、通常タイプと比較して異常度スコアの変化幅が少ないものの同等の変化傾向はみられ、概ね異常検出が可能である。図 5.13 に、ローコストタイプのセンサーを使用して得られた CAE による解析結果の別の例 (第 3 回障害試験時) を示す。図 5.13 に示すように、ローコストタイプセンサーを備えたシステムでも空調機の異常検知が可能である。ローコストタイプセンサーでは、通常タイプセンサーより分離性能が劣るため (図 5.6 参照)、異常検出が若干遅れるもののオフィス環境での実利用には

*1 本研究では単月のデータモデルで評価したが、今後、夏季のデータによる評価を通して、適切なデータモデルの単位を検討する。

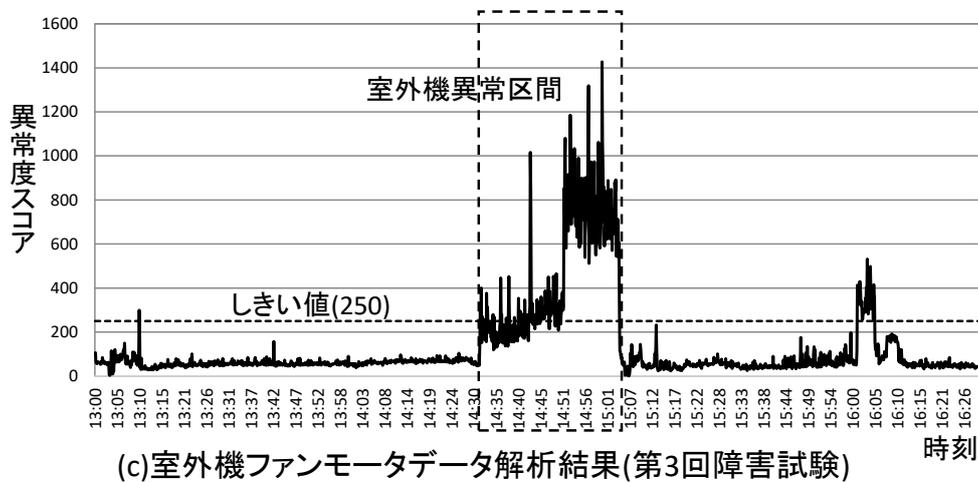
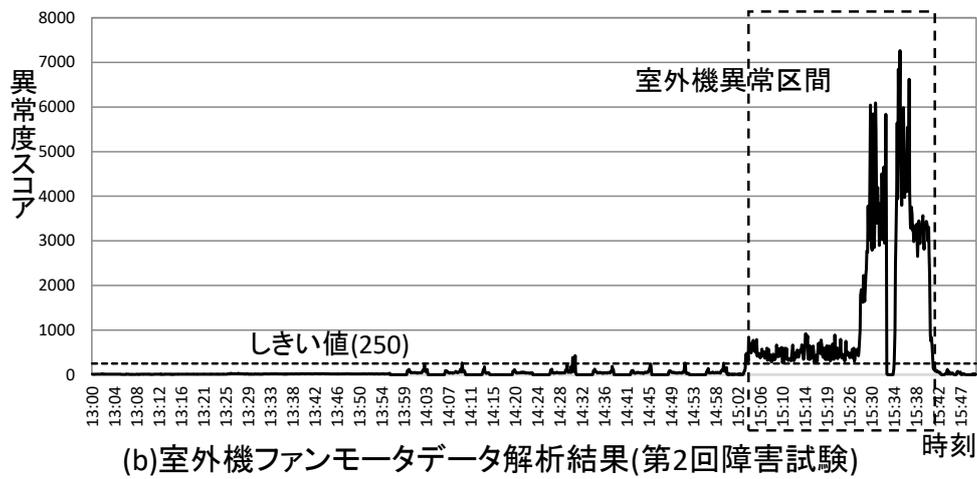
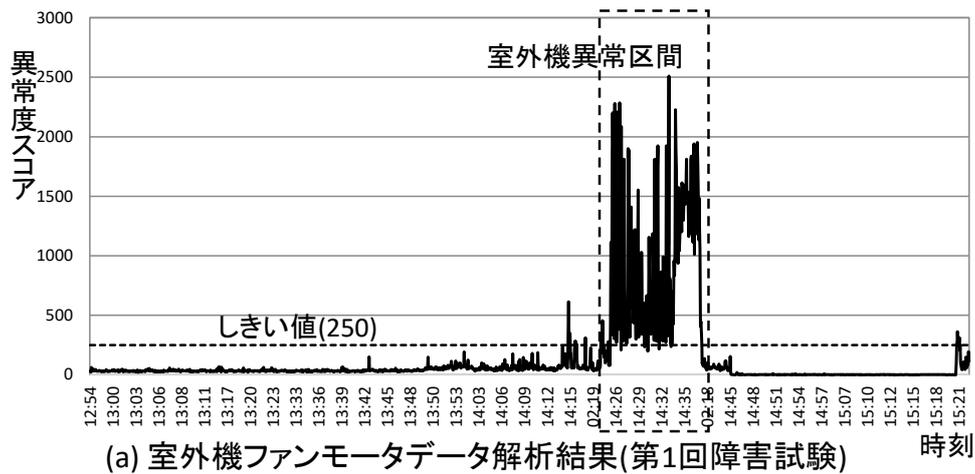


図 5.9 単月データモデル(提案方式)による解析結果

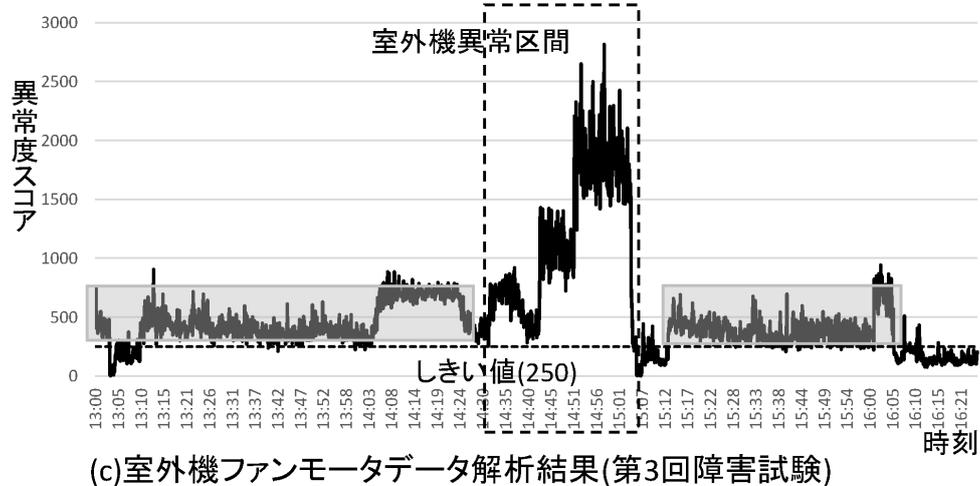
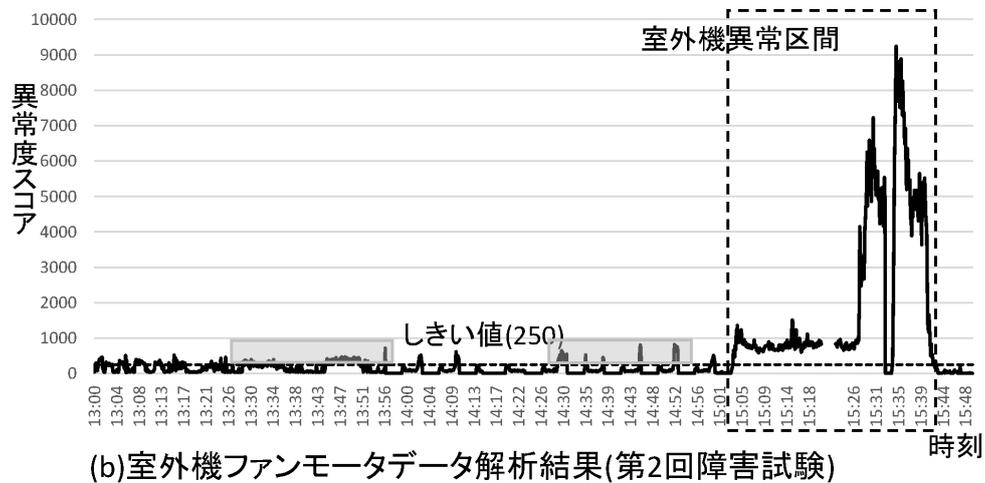
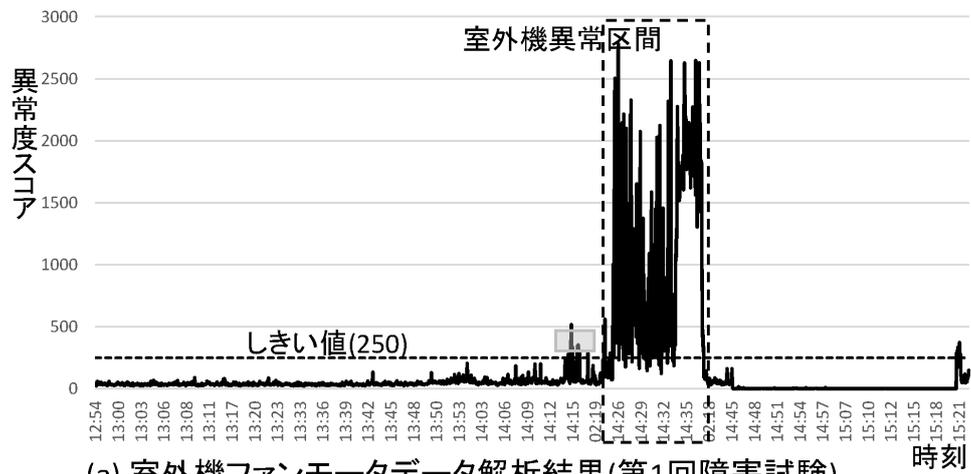


図 5.10 複数月統合データモデルによる解析結果

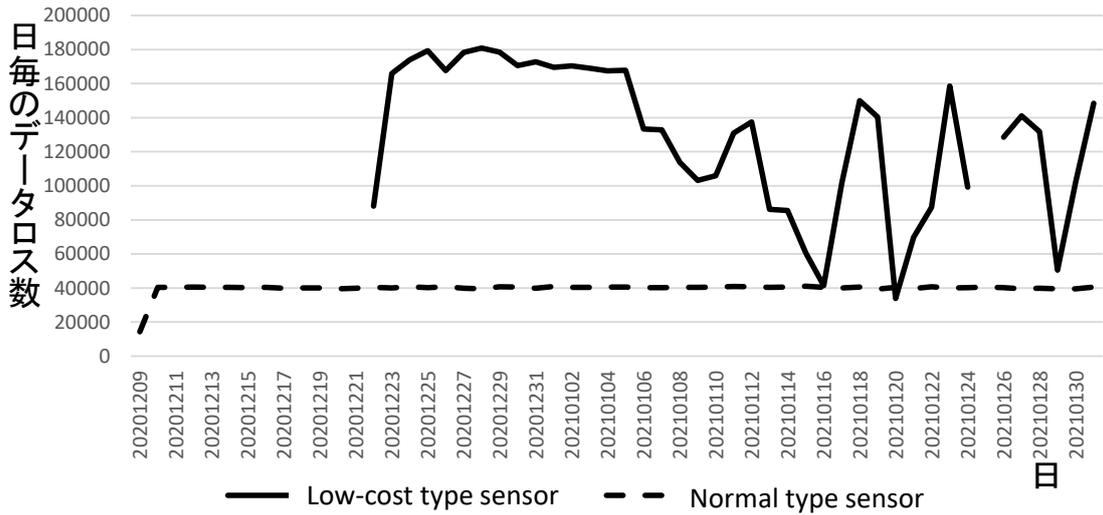


図 5.11 ローコストタイプセンサーのデータロス数

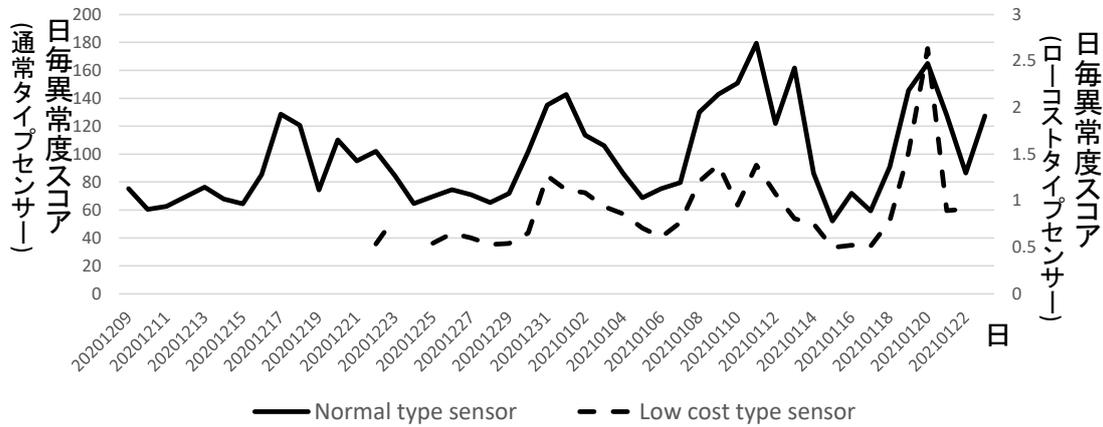


図 5.12 ローコストタイプセンサーと通常タイプセンサーの異常度の推移

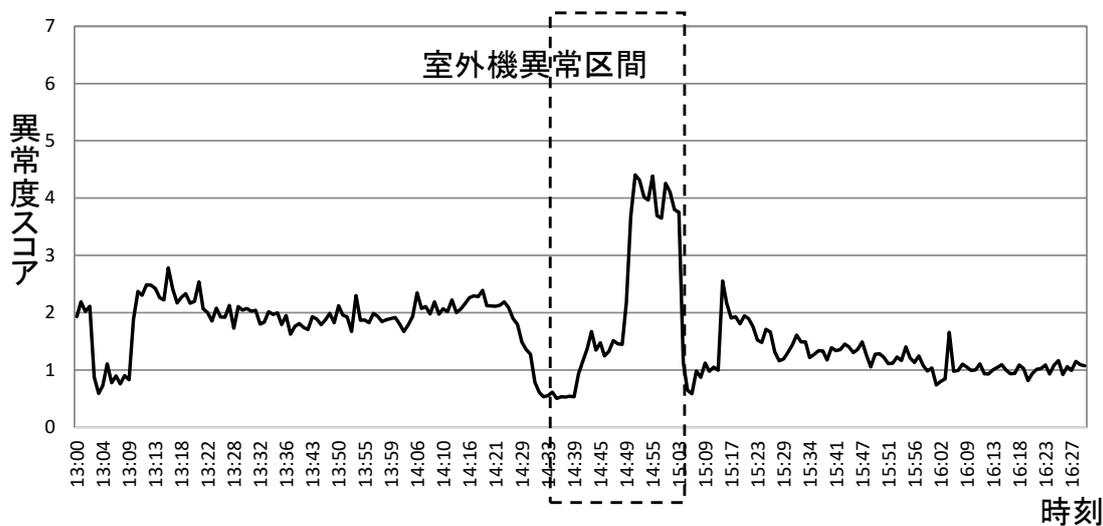


図 5.13 第 3 回障害試験におけるローコストタイプのセンサーを使用した室外機ファンモーター解析結果

耐えられると考えられる。

5.5 むすび

本研究では、既設の空調機のデータ収集および診断システムを構築するための手法を提案した。ノイズの多い環境、コスト制約および季節的な変化が空調機の異常検出と診断の課題であった。空調機の異常の半数以上を占めるフィルター等の目詰まりによる風量の減少などの事象を早期に発見するために、主要部品(コンプレッサー、屋外ファンモーター、膨張弁、屋内ファンモーター)に振動センサーと温度センサーを設置しセンサーデータを収集した。開発したシステムの特徴は以下のとおりである。

- 低コストのセンサーを使用を可能とするデータ収集システム構築と診断方法の導入により設置コストを削減した。
- 異常の検出精度を向上させるため、季節性を考慮した診断モデルの生成方法を提案した。

更に、この研究では、提案手法の妥当性と正確さを示す実験結果を報告した。また、本研究では、3.8節で示した開発プロセスを適用しており、その一般性が確認できた。

第 6 章

総括と今後の研究展望

本研究では、プラント監視システムにおいて、データ収集から分析までの全体システムを設計する過程で留意すべき点を明確にして、適切な開発プロセスを提示した。開発プロセスは、飼料工場における監視システムおよび空調機システムの故障診断の開発を通して明らかにした。各章で述べた研究の成果を述べる。

6.1 プラント監視システムの実現プロセスと AI 応用診断技術に関する研究

本研究では、飼料プラントにおいて、原材料の粉砕装置であるロール機を対象とし、故障の生じやすい駆動部に振動センサーと温度センサーを設置しセンサーデータを収集、また、消費電力量も収集しこれらのデータを分析するプラント監視システムを開発した。開発したシステムの特徴は以下のとおりである。

- 状態監視システム

振動データからプラントの状態を理解できるようにするためのステータス監視用のラベル付け機能を開発した。消費電力と振動パターンの関連性に着目し、稼働状態が振動データでカテゴリ分類可能であることを確認するとともに、振動データを用いた故障予知システムと部品交換時期分析システムの開発の妥当性を確認した。本システムでは、3 軸の加速度値を FFT 処理したスペクトル強度を入力とし、消費電力量によってカテゴリに分類した。分類手法は、CNN とランダムフォレストを用い、結果的にやや分類精度の高い CNN を採用した。

- 故障予知システム

解析手法の有効性の事前確認のため、小型モータを用いた実験システムで振動データの解析を実施した。実験システムでは、観測データと正常運転時のデータの差から異常を検知する4手法 (Autoencoder, 疎構造学習, k-近傍法, 密度比推定法) を評価し、人工的な異常の検出精度、計算時間の観点から Autoencoder と疎構造学習を採用した。これらの手法は実プラントに適用した結果、ベアリングでの温度上昇と疎構造学習による振動データの異常度スコアの連動性やメインモータで Autoencoder による振動データの異常度スコア上昇の各事象を検知、Autoencoder と疎構造学習の2つの手法の組み合わせでの異常検知が現実的であることを示した。

- 部品交換時期分析システム

ロール機の定期交換部品である主ロールの適切な交換時期を、1週間の観測データの振動パターンを交換前後に分類し、その出現割合から判定できることを示した。分析モデルの生成には、疎構造学習と CNN の2手法を評価した。1週間のデータの中で交換後と判定された観測データの出現割合を交換後判定比率とし、交換後判定比率が低いほど交換時期に近づいていることを示している。観測データの交換後判定比率を週ごとに計算し、しきい値と比較することで交換時期を判断することとし、実験結果から外挿してしきい値は概ね 20% と想定した。

- データ収集システム

データ収集システムの全体設計を行い、解析手法毎に、適切なデータ収集速度を求めた。センサーおよび通信方法は、開発時点で一般に流通している機器の中から価格・性能を考慮して妥当な機種を選択した。センサー側の通信方式は、温度センサーは Wi-Fi、加速度センサーは Bluetooth、電力計は RS485 を用いた。制御室に設置した PC にデータを転送するため、センサーから収集したデータは、IoT-GW で一旦集約する構成とした。

データ収集では、振動データの量が特に多く、データ収集と分析にかかるコストを削減するため、データ分析結果に影響を与えない必要最小限のサンプリングレートとデータ収集周期を求めた。状態監視の場合、CNN では1軸 (Y軸) 振動センサーで 25Hz のサンプリングレートで十分、故障予知では、Autoencoder を用いた場合、1軸 (Y軸) 振動センサーで 10Hz のサンプリングレートで十分である。しかし、CNN による部品交換時期分析には、3軸振動センサーで 25Hz のサンプリング

レートが必要であることを示した。

6.2 プラント監視データ収集システムに関する研究

本研究ではプラント監視システムにおけるデータ収集システムの構築に焦点を当てて、3章で述べたデータ分析目的(状態監視、故障予知、部品交換時期分析)に必要なデータ量を安定的に収集するための課題と解決策を提案した。開発したシステムの特徴は以下のとおりである。

- 安定的な通信の確保

3章で述べたデータ収集能力を実現するためのセンサーとIoT-GW間、IoT-GWとPC間の通信方式を性能や安定性の観点から議論した。センサーとIoT-GW間の通信では、電磁波等のノイズ影響で加速度センサーで使用するBluetooth通信が不安定で、1日を通してみた場合、通信切断は100%発生、人手によるセンサーのリセット操作を必要としていた。これに対して、センサーとIoT-GWの間に中継器を設けBluetooth通信を送信出力の大きいWi-Fiに変換するとともに、中継器からセンサー側(Bluetooth通信)に定期的に送信する特定コマンドで接続監視を行い、センサー側で一定時間特定コマンドの受信ができなかった場合、Bluetooth再接続処理に移行するようにした。これにより、通信切断時の自動回復を実現した。提案方式では、データロス率(1時間のうち通信できなかった時間の割合)は概ね10%~20%程度で推移し、通信切断時は概ね160秒以内でデータ通信が回復する。これは、3章の事例からも異常検知に耐えられると判断した。また、通信性能に関しては、センサーとIoT-GW間、IoT-GWとPC間のそれぞれで収集データ量と通信容量から評価し、十分余裕があることを示した。さらに、IoT-GWとPC間の通信障害でデータの欠損を防ぐため、IoT-GW上のセンサーデータは、PC側からポーリングによる回収があるまで保持する方式とし、IoT-GWとPC間の1時間程度の通信障害では1時間程度で自動回復可能であることを示した。

- 全体システム構成

収集データの集約方法では、外部からの稼働状態の監視およびデータ分析が必要であったためクラウドへの集約を選択した。IoT機器の導入容易性、耐久性、コスト

を考慮、センサーデータは IoT-GW で無線通信により収集し、セキュリティ対策で有利な IoT-GW から PC に一旦集約してからクラウドに転送する方式とした。

- IoT 機器の選定と設置

センサーの仕様および必要な通信帯域は 3 章で示した故障診断要求事項に基づく収集データ速度から決定、機種選定を行った。また、既存設備への影響がないように、IoT 機器の設置、ケーブルの敷設を適切に実施した。

6.3 プラント監視方式の空調機システムへの応用に関する研究

本研究では、空調機のデータ収集および診断システムを構築するための方法を提案した。ノイズの多い環境、コストの制約、および季節的な変化が空調機の異常の検出と診断の課題であった。空調機の異常の半数以上は、フィルター等の目詰まりによる風量の減少が原因である。このような事象を早期に発見するために、主要部品 (コンプレッサー、屋外ファンモーター、膨張弁、屋内ファンモーターに) に振動センサーと温度センサーを設置しセンサーデータを収集した。開発したシステムの特徴は以下のとおりである。本研究では、6.1 節、6.2 節の研究成果を適用しており、その一般性を確認した。

- 異常検知システム

各センサーから収集したデータは IoT-GW に集約し、クラウドを経由してデータ分析サーバに転送する構成とした。データ分析は、観測データと正常運転時のデータの差から異常を検知するいくつかの方式を評価した結果、Convolutional Autoencoder と Isolation Forest を使用した。実証実験では、冬季 2 か月の通常運転データと室内機、室外機それぞれの吸入口を塞ぐ障害試験 (目詰まりによる風量の減少を模擬) を冬季 2 回、夏季 1 回実施し、異常時のデータを収集した。通常運転データから学習モデルを作成し、異常時のデータも含めて異常判定のしきい値を設定した。

- センサー位置の評価

空調機の運転パターン (冷暖房など) は季節によって異なるため、異常を正確に検出できるセンサーの位置は異なることが分かった。コンプレッサーと膨張弁は、夏季の室外機側故障と室内機側故障を検出できるが、冬には検出できない。一方、季

節に関係なく、室外機側の故障は室外ファンモーターで検出でき、室内ファンモーターは室内機側の故障を検知できる。

- 季節性の評価

季節性や気候が空調機の運転に与える影響を考慮した異常検出精度向上方式として、季節ごとに異なる学習モデルを使用し、観測データの異常度が最も低いモデルを採用することとした。提案方式(12月、1月、8月の各単独モデルを使用)と12月-1月統合モデル、8月-12月統合モデルを比較したところ、提案方式では統合モデル(従来方式)と比較して3倍から8倍程度異常検知の分離性能(試験期間中の異常区間の最大値と正常区間の最大値の比)が向上した。

- ローコストセンサーの評価

コストの問題に対処するために、通常タイプの振動センサーに加えてローコストタイプの振動センサーを評価した。通常タイプのサンプリングレート50Hzに対して、ローコストタイプでは10Hzであった。ローコストセンサーによるデータ損失の数は、受信する必要があるデータ数に対して、2%から20%で、通常タイプセンサー(1%以下)よりも大きい。ローコストタイプセンサーでは、通常タイプと比較して異常度スコアの変化幅が少ないものの同等の変化傾向はみられ、障害試験の結果からは通常タイプと比較して異常検知の分離性能が下がるものの検知は可能である。これにより、ローコストセンサーでは異常検知に若干の遅れが生じるもののオフィス環境での実利用には耐えられると判断した。

6.4 本研究の成果

2.3節で示した本研究の解決課題に対する成果をまとめる。また、表6.1で研究成果をシステム共通事項とシステム固有事項にまとめる。

6.4.1 プラント監視システムの実現プロセス

プラント監視の開発プロセスと技術選択の留意点をまとめる。

- 監視データの選択

故障による影響の大きい駆動部または故障の影響が表れやすい箇所にセンサーを設

表 6.1 研究成果のシステム共通事項とシステム固有事項

#		本研究での対応(システム共通)	本研究での対応(システム固有)	
1	プラント監視システムの開発プロセス	・監視データの選択、実験室での小規模実験、データ収集速度、システム全体設計	—	
2	既存プラントでのシステム構築	・センサーの選定と設置 - 価格・性能面から選定 - 設置方向・位置、ケーブル敷設経路	—	
		・IoT-GWの選定と設置 - 性能スペック、ネットワークインターフェース(Wi-Fi,Bluetooth)	飼料工場	・監視対象装置周辺に設置可能な大きさと形状 ・防塵対策(プラスチックケース)
3	目的に応じたデータ分析精度の向上	・予備実験と実プラントにおける検証の繰り返し	飼料工場	・目的に応じた適切な分析方式探索
			空調機	・季節性を考慮した分析精度向上方式(季節ごとに異なるモデル)
4	必要十分なデータ収集量/収集方式	・目的に応じたデータ収集間隔とサンプリングレートの決定方法 ・通信性能、信頼性の確保	飼料工場	・状態監視、故障予知、等の目的毎
			空調機	・ローコストセンサーの適用
5	現実に直面した課題解決・評価	・センサーとIoT-GW間の通信切断時の自動回復方式	飼料工場	・IoT-GWとPC間のデータ欠損防止

置し、振動や温度など異常検知に有効なデータを収集する。3章、5章で述べたように、センサーを用いた通常運用状態の確認は重要である。異常判定用の学習モデルは、通常運用状態のデータパターンを含む必要があり、この学習モデルに基づき異常判定のしきい値を設定する。3章の研究では、プラントの状態把握が必要であったためスタータ監視用のラベル付け機能を開発した。

- 実験室での小規模実験

実験室での小規模実験により適用可能な手法を絞り、稼働中のプラントで実験を行う事による現場作業への影響を抑えることができる。また、大量かつ複雑な稼働条件下での実プラントで想定される基本的な状態変化パターンを抽出して単純化することで手法の選定が容易になる。

- データ収集速度

適切なセンサーの選択と、分析のためのデータ収集間隔とサンプリングレートの決定方法について、データ分析の目的毎に必要な最小限の値を検討することにより、適切なデータ収集とデータ解析コストを決定することができる。3章の研究では状態監視、故障予知、部品交換時期分析の各目的毎に検討し、5章の研究では実際にローコストセンサーを適用し評価した。

- システムの全体設計

センサーから収集したデータを安全かつ効率よくサーバー等に集約するための設計である。3章および4章の研究では、外部からの監視およびデータ分析が必要であったためクラウドへのデータ集約を選択、IoT機器の導入容易性、耐久性、コストを考慮、センサーデータはIoT-GWで無線通信により収集し、セキュリティ対策で有利なIoT-GWからPCに一旦集約してからクラウドに転送する方式とした。5章の研究では、小規模構成の実験のため、PCへの集約は行わなかった。センサーの仕様および必要な通信帯域は、故障診断要求事項(分析の目的)に基づく収集データ速度から決定、機種選定を行った。

データ解析手法とそれに必要なデータ収集速度は、設計のポイントである。また、複雑な稼働条件下での検証を効率化するため、予備実験と実プラントにおける検証を繰り返すことで適切なデータ解析手法とデータ収集手法を決定する。

6.4.2 既存プラントの監視システム構築

既存のプラントの運用に影響を与えることなく外付けで監視システムを構築するため、センサーや機器の選定と設置、ケーブルの敷設等のシステム構築上の諸課題と解決策を飼料工場の監視システムおよび空調機システムの故障診断を例に説明した。

- センサーの選定と設置

センサーは各装置の監視箇所にマグネットで設置し、特に加速度センサーでは設置位置・方向は正確に記録し装置のメンテナンス等で取り外した場合も正確に設置を復元できるように運用した。また、センサー部と付属する通信部間のケーブルおよび電源ケーブルの敷設では、適切な経路を選定し、既存の設備の動作への影響を防いだ。

- IoT-GW の選定と設置

監視対象装置当たり 1 台の IoT-GW を設置した。IoT-GW 機器は要求データ量进行处理できる性能スペックを有し、センサー及び PC との通信で必要なインタフェース (Wi-Fi, Bluetooth, RS-485) を具備していることを条件として選定した。3 章で議論した飼料工場では、監視対象装置周辺に設置可能な大きさと形状を配慮し、配電盤内に設置した電力計から RS485 で引き込むために監視対象装置の配電盤付近に防塵対策のためプラスチックケースに収容し設置した。

6.4.3 目的に応じたデータ分析の精度向上

運転パターンの変化など機器固有の故障診断や最適な部品交換時期分析のためのデータ分析精度の向上のため、飼料工場の監視システムと、空調機システムの故障診断それぞれ対象に応じた方式を提案した。

- 飼料工場の監視システム

予備実験と実プラントにおける検証を繰り返すことで、分析目的に応じた適切な分析方式を決定した。状態監視システムでは CNN を、故障予知システムでは Autoencoder と疎構造学習を、部品交換時期予測では CNN と疎構造学習を用いた。

- 空調機システムの故障診断

季節性や気候が空調機の運転に与える影響を考慮した異常検知方式として、季節ごとに異なる学習モデルを使用し、観測データの異常度が最も低いモデルを採用する方式を適用し、異常検知精度を向上させた。

6.4.4 データ分析に必要な十分なデータ収集量/収集方法

飼料工場の監視システムでは、分析のためのデータ収集間隔とサンプリングレートの決定方法について、必要最小限の値を状態監視、故障予知、部品交換時期分析の各目的毎に検討し、データ収集とデータ解析コストの最適化を図った。空調機システムの故障診断では、実際にローコストセンサーを適用しオフィス等の実環境では適用可能であることを示した。

6.4.5 現実に直面した課題解決・評価

飼料工場の監視システムでは、センサーと IoT-GW 間の通信が電磁波等のノイズ影響で不安定であった。この問題に対して、発生を前提にデータ通信の自動回復処理方式を提案、一定のデータロスが発生するものの、通信の継続を確保でき、異常検知や故障診断では、実用上問題にならないことを示した。また、IoT-GW と PC 間の通信障害でデータの欠損を防ぐための方式を提案した。通信性能に関しては、センサーと IoT-GW 間、IoT-GW と PC 間のそれぞれで収集データ量と通信容量から評価し、運用に支障がないことを示した。

6.5 今後の研究展望

本研究では、IoT やデータ分析の技術を実際の工場の監視システムに導入するための適切な技術選択過程を具体的なシステム構築事例に基づき明らかにした。提案した開発プロセスは、本研究で開発したシステムの継続した運用によるフィードバックにより継続して改善を図る。また、本開発プロセスは、飼料工場の監視システムおよび空調機システムの故障診断に適用した実績を踏まえ、産業分野で幅広く適用できると考えており、他のシステムでもこれを実践していくとともに得られた知見をフィードバックし改善していく。本研究で今後の課題とした以下の項目については継続して推進する。

- 異常検知事例を積み上げることで異常検知精度の向上を図る。
- 部品交換時期分析システムにおける適切なしきい値を決定する。
- Bluetooth 通信障害からの回復の適切なスリープ時間を決定する。
- 空調機システムでは、夏季のデータを蓄積し、年間を通じた適切なデータモデルを構築する。

謝辞

本論文の作成にあたり終始適切な助言を賜り、また丁寧に指導して下さった吉田健一教授に感謝します。研究のアプローチや考察の方法などについて適切な助言をいただいた片岸一起教授、倉橋節也教授、木野泰伸教授、千葉商科大学 寺野隆雄教授にも心より感謝申し上げます。また、本研究に協力いただいたコンピュータロン株式会社、明治機械株式会社、ダイコウ技研株式会社の関係方々に感謝申し上げます。

参考文献

- [1] 経済産業研究所, “2017 年版ものづくり白書 – IoT 社会における製造業の課題と政府の取組”
- [2] 経済産業省, 厚生労働省, 文部科学省, 2021 年版 ものづくり白書, (令和 2 年度 ものづくり基盤技術の振興施策, 令和 3 年 5 月
- [3] 総務省, 情報通信白書平成 30 年度版, 第 1 部, 第 2 節 ICT による生産性向上方策と効果 (2) AI・IoT の導入にあたっての課題
- [4] 総務省, 情報通信白書平成 29 年版, 第 1 部 特集 データ主導経済と社会変革, 第 3 節 IoT 化する情報通信産業 (2) LPWA
- [5] 境野 哲, IoT への期待と課題～IoT システム開発者・利用者の心得～, 情報の科学と技術, 67 巻, 11 号, pp.560-565, 2017.
- [6] 清尾克彦, オープン環境による M2M/IoT システム構築の動向と取り組み事例, e ラーニング研究, 第 4 号, 2015.
- [7] 清尾克彦, M2M (Machine to Machine) 技術の動向と応用事例, サイバー大学紀要第 5 号, pp.1-22, 2013.
- [8] 大江信宏, 堂坂 辰, 北上真二, 金子洋介, 井上雅裕, 中島 毅, 汐月哲夫, 小泉寿男, アイディアに基づく M2M/IoT プロトタイプシステム構築法の提案と実践, 電気学会論文誌 C, 137 巻 10 号 p. 1402-1413, 2017.
- [9] 辻井 秀一, 澤本 潤, 清尾克彦, 北上真二, M2M (Machine-to-Machine) 技術の動向, 電気学会論文誌 C, 133 巻 3 号 p. 520-531, 2013.
- [10] 近藤, 振動のオクターブバンド分析を用いた異常検知法による車両機器の診断, 日本機械学会論文集, Vol.84, No.862, 2018.
- [11] 貝戸, 数実, 統計的变化点検知に基づく社会基盤施設の早期異常検知, REAJ 誌, Vol37, No3, pp.116-125, 2015.

- [12] 野村, 井田, 宮地, 宮本, 菅, 深層学習に基づく配管バルブの健全性モニタリング, 土木学会論文誌 F6(安全問題), Vol.72, No2, I183-I190, 2016.
- [13] 緒方淳, 村川正宏, 飯田誠, 風力発電スマートメンテナンスのための振動データ解析に基づく状態監視システムの構築, 風力エネルギー利用シンポジウム, 第 37 巻, pp.385-388, 2015.
- [14] 小野田 崇, 伊藤 憲彦, 是枝 英明, 水力発電所における異常予兆発見支援ツールの開発, 電気学会論文誌 D, 131 巻 4 号 p. 448-457, 2011.
- [15] N. I. Haque, M. A. Rahman, H. Shahriar, Ensemble-Based Efficient Anomaly Detection for Smart Building Control Systems, Proceedings of COMPSAC2021, pp504-513.
- [16] K. Krishna Kishore, M.H. Sai Kumar, M. B. S. Murthy, Automatic plant monitoring system, Proceedings of 2017 ICEI, May 2017.
- [17] I. Marcu, G. Suciuc, C. Bălăceanu, A. M. Drăgulinescu, M. Alexandru Dobrea, IoT Solution for Plant Monitoring in Smart Agriculture, Proceedings of 2019 SIITME, Oct. 2019.
- [18] 今井 健, 上野 洋平, 監視制御データからのプラント運転パターン抽出手法の検討, 電気学会, 分野横断型新システム創成研究会, pp.29-34, 2021
- [19] 高須 素志, 岡 誠司, 野村 真澄, 工藤 敏文, 星島 秀之, ICT と AI 技術活用による GTCC 運転・監視業務の負担軽減の取り組み, 三菱重工技報 Vol.54 No.3 (2017), pp.74-79.
- [20] 小田和弘, 近藤誠治, 谷宏幸, 佐子朋生, 火力発電プラントの異常兆候検知システム, 三菱電機技報, Vol.93, No.11, pp.16-19.
- [21] 西郷宏治, 渡辺 悟, 岩崎哲之, 産業用電動力応用プラントの運転・監視システム, 富士時報 Vol.70 No.10, pp.550-553 1997.
- [22] 小宮山茂雄, 宮添 東, 山田哲也, 長谷川邦夫, 最近の化学プラントの計測制御技術, 日立評論 VOL.57 No.3(1975-3), pp.25-30.
- [23] 瀬戸洋一編著, 技術者のための IoT の技術と応用, 日本工業出版社, 平成 28 年
- [24] 稲田修一監修, M2M/IoT 教科書, インプレス, 2015 年
- [25] 池邊 隆, IoT の技術動向について, tokugiken no.286, pp.36-46, 2017
- [26] M. Taneja, A Mobility Analytics Framework for Internet of Things, Proceedings of

- 2015 ICGCIoT, pp.113-118, 2015
- [27] H. Xue, B. Huang, B. Huang, M. Qin, H. Zhou, Hua Zhou, H. Yang, Edge Computing for Internet of Things: A Survey, Proceedings of 2020 Things-Green and Com-CPS and Com-Smart and Data-Cybermatics, pp.755-760, 2020.
- [28] D. Loghin, L. Ramapantulu, Y. M. Teo, Towards Analyzing the Performance of Hybrid Edge-Cloud Processing, Proceedings of 2019 EDGE, pp.87-94.
- [29] T. Kono, Y. Taito, and H. Hidaka, Essential Roles, Challenges and Development of Embedded MCU Micro-Systems to Innovate Edge Computing for the IoT/AI Age, IEICE TRANS. ELECTRON., VOL.E103-C, NO.4 APRIL 2020, pp.132-143
- [30] 高尾大樹, 杉浦健人, 石川佳治, エッジコンピューティングにおける低遅延かつ高信頼度なデータストリームの近似的集約処理, 電子情報通信学会論文誌 D Vol. J104-D No. 5 pp. 463-475.
- [31] 五十嵐昭男, 転がり軸受の異常の検出方法について, ターボ機械第7巻第10号, pp.40-45, 1979.10
- [32] 北井正嗣, 赤松良信, 福井健一, 転がり軸受の損傷検出精度向上のための機械学習アルゴリズムの開発, NTN TECHNICAL REVIEW No.88, pp.86-98
- [33] K. Fukae, T. Imai, T. Kobayashi, K. Arai, S. Yamabe, Development of Observation Device with Multi Sensor Platform for Underwater Aquaculture Cages, Proceedings COMPSAC2021, pp.1634-1639, 2021
- [34] 井手 剛, 入門機械学習による異常検知, コロナ社, 2015.
- [35] 井手 剛, 杉山 将, 異常検知と変化検知, 機械学習プロフェッショナルシリーズ, 講談社, pp.127-154, 2015.
- [36] 山西, 異常検知: 外れ値検知と変化検知, REAJ 誌, Vol37, NO. 3(通巻 223 号), 2015.
- [37] N. Gornitz et al, "Toward supervised anomaly detection," Journal of Artificial Intelligence Research, 2013.
- [38] Alistair Shilton, Sutharshan Rajasegarar, arimuthu Palaniswami, Combined multiclass classification and anomaly detection for large-scale Wireless Sensor Networks, 2013 IEEE Eighth International Conference on Intelligent Sensors, Sensor Networks and Information Processing, April 2013.
- [39] Vilen Jumutc, Johan A. K. Suykens, Multi-Class Supervised Novelty Detection,

- IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014.
- [40] Y. LeCun, B.E. Boser, J.S. Denker, D. Henderson, R.E. Howard, W.E. Hubbard, and L.D. Jackel. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, Vol.1, No.4, pp.541-551, 1989.
- [41] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, Vol.86, No.11, pp2278-2324, 1998.
- [42] Leo Breiman, Random Forests, *Machine Learning*, Vol.45 Issue 1, pp.5-32, October 1 2001.
- [43] 山下隆義, ディープラーニング, 講談社, pp.44-47, 2016.
- [44] Dempster, A.P., Covariance selection. *Biometrics*, Vol.28, No.1, pp.157-175
- [45] 宮川, グラフィカルモデリング, 朝倉書店, pp.72-95, 1997.
- [46] G.E. Hinton and R. Salakhutdinov, Reducing the dimensionality of data with neural networks, *Science*, Vol.313, No.5786, pp.504-507, 2006.
- [47] python と実例で学ぶ機械学習 識別・予測・異常検知, オーム社, pp.87-108, 2018
- [48] E. Riley, F. Efraim, Deep Semi-Supervised Embedding for Dynamic Targeted Anomaly Detection, *AAAI*, 2017
- [49] R. Chalapathy, A. K. Menon, S. Chawla, Anomaly Detection Using One-Class Neural Networks, arXiv.1802.06360v2 [cs.LG] 11 Jan 2019.
- [50] 杉山 将, 密度比推定によるビッグデータ解析, *電子情報通信学会誌*, vol.97, no.5, pp.353-358, 2014
- [51] B. Scholkopf, R. Williamson, A. Smola, J. Shawe-Taylor, J. Platt, Support Vector Method for Novelty Detection, *Neural Information Processing Systems 1999*, pp.582-588.
- [52] G. Taguchi, R. Jugulum, *The Mahalanobis-Taguchi Strategy: A Pattern Technology System*, Wiley 2002.
- [53] C. Chen, J. Liu, Y. Xie, Y. X. Ban, C. Wu, Y. Tao and H. Song, Latent Regularized Generative Dual Adversarial Network For Abnormal Detection, *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence (IJCAI-20)*, pp.760-766. 2020

- [54] 服部聖彦, 高玉圭樹, 大谷雅之, 松島裕康, 佐藤圭二, 市川嘉裕, 超大規模センサネットワークに適応したセンサデータ収集・分散故障診断アルゴリズム, 計測自動制御学会論文集, Vol.48, No.11, pp.745-753, 2012
- [55] 宇谷明秀, 織戸英佑, 熊本紋子, 山本尚生, 大規模センサネットワークのための Ant-based Routing アルゴリズムの高度化, 計測自動制御学会論文集, Vo1.44,No.4,pp.351-360, 2008
- [56] T. Kubo and T. Kawakami, An Enhanced Routing Method for Overlay Networks Based on Multiple Different Time Intervals, Proceedings of COMPSAC 2021, pp.1560-1565.
- [57] X. Jiang, D. Li, S. Nie, J. Luo, Z. Lu, An Enhanced IOT Gateway in a Broadcast System, 2012 9th International Conference on Ubiquitous Intelligence and Computing and 9th International Conference on Autonomic and Trusted Computing, pp.746-751.
- [58] H. Ko, J. Lee, S. Pack, Consistency-Guaranteed and Energy Efficient Sleep Scheduling Algorithm with Data Aggregation for IoT, 23th European Wireless Conference, May 2017.
- [59] S. Iellamo, R. Guiazon, M. Coupechoux, K. Wong, Securing IoT Uplink Communications Against Eavesdropping, 2018 3rd Cloudification of the Internet of Things (CIoT), July 2018.
- [60] T. Kim, L. F. Vecchiotti, K. Choi, S. Lee, D. Har, Machine Learning for Advanced Wireless Sensor Networks: A Review, IEEE Sensors Journal (Volume: 21, Issue: 11, June1, 1 2021), pp.12379 - 12397
- [61] Shahina K.; V. Vaidehi, Clustering and Data Aggregation in Wireless Sensor Networks Using Machine Learning Algorithms, Proceedings of 2018 ICRTA, Sept. 2018,
- [62] 富田達夫, IoT とサイバーセキュリティ, 情報処理推進機構, 2017.6.2
- [63] V. Bhuvaneshwari, R. Porkodi, The Internet of Things (IoT) Applications and Communication Enabling Technology Standards: An Overview, 2014 International Conference on Intelligent Computing Applications, Mar. 2014, pp.324-329.
- [64] 相原健郎, サイバーフィジカルシステムでの実世界データ収集, 電子情報通信学会 B 論文誌 Vol.J102-B No6 pp.387-398,2019.

- [65] 松井進, IoT システムの技術動向と実用化に向けた取り組み, 電子情報通信学会 C 論文誌, Vol. J100-C No.4 pp.151-158,2017.
- [66] 繁田亮, 川原圭博, 農業用センサーシステムに見るエンドツーエンドの IoT アプリケーションの設計, 電子情報通信学会 B 論文誌 Vol. J102-B, No6, pp.399-412,2019.
- [67] D. Ulusar, G. Celik, F. Al-Turjman, Wireless Communication Aspects in the Internet of Things: An Overview,2017 IEEE 42nd Conference on Local Computer Networks Workshops, Oct. 2017, pp.165-169.
- [68] C. Zhong, Z. Zhu, R. Huang, Study on the IOT Architecture and Gateway Technology, 2015 14th International Symposium on Distributed Computing and Applications for Business Engineering and Science, Aug. 2015, pp.196-199.
- [69] 森部智也, 岡田啓, 小林健太郎, 片山正昭, 圃場における無線センサーネットワークのための 920Mhz 帯電波伝搬特性評価, 農業情報学会, 農業情報研究 26(1), 2017.1-10, pp.1-10.
- [70] 鈴木一哉, 森本昌治, 岩井孝法, IoT 技術の最新動向, 電子情報通信学会ソサエティマガジン, No45 夏号, 2018,pp.12-20.
- [71] 石田康弘, 小野陽二, データ通信におけるノイズの影響と改善に関する研究, 放射ノイズ測定値を用いた波源探知方法の提案, 平成 8 年度 福岡県工業技術センター研究報告 (第 7 号)
- [72] 電子情報通信学会「知識ベース」S4 群 (宇宙・環境・社会)-1 編 (電波環境)1 章, 電子情報通信学会,2017.
- [73] S. G. Abbas, M. Husnain, U. U. Fayyaz, F. Shahzad, G. A. Shah, K. Zafar, IoT-Sphere: A Framework To Secure IoT Devices From Becoming Attack Target And Attack Source, Proceedings of 2020 IEEE 19th TrustCom, pp.1402-1409.
- [74] P. L. R. Chze, K. S. Leong, A Secure Multi-Hop Routing for IoT Communication, Proceedings of 2014 IEEE WF-IoT, pp.428-432.
- [75] A. J. A. Majumdera, C. B. Veilleux, J. D. Miller, Cyber-Physical System to Detect IoT Security Threats of a Smart Home Heterogeneous Wireless Sensor Node, IEEE ACCESS, Digital Object Identifier 10.1109/ACCESS.2020.3037032, pp.205989-206002.
- [76] 総務省北陸総合通信局「子供を見守る ICT 技術に関する調査検討会 報告書」第 2 章

IoTを支える近距離無線通信技術, 平成19年3月

- [77] 北山匡史, 田所通博, 高速電力線通信の現状と技術課題, *IP SJ Magazine*, Vol.47, No.8, Aug. 2006, pp.867-871.
- [78] RS485の通信プロトコルについて、ソフテックだより 第125号、2010.11.2, https://www.softech.co.jp/mm101102_firm.htm
- [79] Richard Anslow、RS-485の性能向上長距離フィールドバスケーブル向けに最適化したレシーバーのフェイルセーフ、ヒステリシス、コモンモード電圧範囲およびゲイン帯域幅、ANALOG DEVICES アプリケーションノート、AN1399、2017.3
- [80] R. Ito, M. Tsukada, M. Kondo, H. Matsutani, An Adaptive Abnormal Behavior Detection using Online Sequential Learning, 2019 IEEE CSE and IEEE EUC, pp.436-440.
- [81] N.-Y. Liang, G.-B. Huang, P. Saratchandran, and N. Sundararajan, Fast and Accurate Online Sequential Learning Algorithm for Feedforward Networks, *IEEE Transactions on Neural Networks*, vol.17, no.6, pp.1411-1423, Nov. 2006.
- [82] Y. Harada, Y. Yamagata, O. Mizuno, E. Choi,)Log-based Anomaly Detection of CPS Using a Statistical Method, *IWESEP2017*, March 13 2017.
- [83] M.M. Breunig, H.-P. Kriegel, R.T. Ng, and J. Sander, LOF: Identifying Density-Based Local Outliers, *Proc. of SIGMOD*, pp.1-12, 2000.
- [84] N. Shi, X. Yuan, J. Hernandez, K. Roy, A. Esterline, Self-learning Semi-supervised Machine Learning for Network Intrusion detection, 2018 CSCI, pp.59-64.
- [85] S. Ravi, Semi-supervised Learning in Support Vector Machines. Project Report COS521, 2014.
- [86] M. Nadeem, O. Marshall, S. Singh, X. Fang and X. Yuan, Semi-supervised Deep Neural Network for Network Intrusion Detection. *CCERP 2016*.
- [87] W. Song, N. Feng, Y. Tian, S. Fong, An IoT-Based Smart Controlling System of Air Conditioner for High Energy Efficiency, 2017 IEEE iThings and IEEE GreenCom and IEEE CPSCom and IEEE SmartData, pp.442-449
- [88] A. Jiang, H. Wei, J. Deng, and H. Qin, Cloud-Edge Cooperative Model and Closed-Loop Control Strategy for the Price Response of Large-Scale Air Conditioners Considering Data Packet Dropouts, *IEEE TRANSACTIONS ON SMART*

GRID, VOL. 11, NO. 5, SEPTEMBER 2020, pp.4201-4211.

- [89] 山本亨, 羽山広文, 林 添生, 中央監視装置の遠隔操作による省エネルギー自動運用システムの開発と実証, 空気調和・衛生工学論文集, No.274, 2000.1
- [90] 蜷川忠三, 佐藤友孝, インターネット Web 連携通信による広域ビル空調監視 - 通信性能・信頼性の改善-, 三菱重工技報 Vol.48 No.2 (2011), pp.13-21
- [91] 菅 百合野, 長澤浩司, 塩地純夫, ビル用マルチ運転データ分析用データベースの開発, 空気調和・衛生工学会大会学術講演論文集, 2015.9.16-18 (大阪), 第3巻, pp413-416.
- [92] 馬場 宣明, 戸倉 伯之, 渋谷 久恵, 岡 恵子, 國眼 陽子, 空調 IoT ソリューション「exiida 遠隔監視-予兆診断サービス」の展開, 日立評論, Vol.101 No.05 582-583
- [93] A. Alqahtani, X. Xie, J. Deng, M.W.Jones: A Deep Convolutional Auto-encoder with embedded clustering, 2018 25th IEEE International Conference on Image Processing.
- [94] F. Tony, L. Kai, M. Ting, Z.-H Zhou, Isolation forest, ICDM 2008, pp.413-422, 2008/12/15

関連業績リスト

第3章 平田俊明, 吉田健一, 古井戸邦彦, 松井三栄登, ”IoT 技術を用いたプラント監視システムの実現”, 電子情報通信学会 D 論文誌, Vol.J103-D, No.12, pp.871-880, 2020.

T.Hirata,K.Yoshida,K.Koido,S.Mastui,Plant monitoring system with IoT facilities,Proceedings of ICOIN2020, pp.547-552, Jan.2020.

第4章 平田俊明, 吉田健一, 古井戸邦彦, 松井三栄登, ”プラント監視データ収集システムの要求仕様とその実現”, 電気学会論文誌 C,Vol.141 No.10, pp.1069-1076, 2021.

第5章 T.Hirata,K.Yoshida,K.Koido,S.Takahashi,Anomaly detection in air conditioners using IoT technologies,Proceedings of COMPSAC2021, pp.1553-1559, Jul.2021.