

2025年度

博士学位論文

SCADA データ分析に基づく
風車ブレード雷被害検出手法に関する研究

中部大学大学院

工学研究科 電気電子工学専攻

松井 拓斗

論文要旨

日本国内では、風力発電が再生可能エネルギー主力電源化の「切り札」として注目される一方、冬季雷による風車の雷被害が問題視されている。冬季雷は、日本海沿岸部で多発する現象であり、雷電流の持続時間が長くエネルギーが大きいという特徴を持つ。日本の風車の約4分の1は風況の良い日本海沿岸部に建てられているため、多くの風車で冬季雷による被害が報告されている。これらの事故の一部では、回転中の風車ブレードが亀裂や貫通破壊などの致命的な損傷を受け、遠心力によって損傷が拡大し、構成部品を周辺に落下させる危険な二次被害を引き起こしている。

このような課題を背景に、日本では風車雷被害の低減に向けた法整備が進んでいる。経済産業省の定める「発電用風力設備における技術基準の解釈」では、国内の風車に対して落雷検出装置（Lightning Detection System: LDS）の設置が義務付けられ、風車への雷撃があれば直ちに運転を停止することを求めている。この規制により、雷を受けた風車の安全な停止が可能となり、公衆安全を脅かす深刻な被害は低減された。

しかしながら、落雷検知から再稼働までの点検過程は、風車の稼働率を低下させる原因となっており、問題視されている。多くの場合、風車の健全性は電気主任技術者の指導のもと作業員の目視点検によって確認される。そのため、修繕の可否を問わず作業には時間を要する。洋上風力発電や山間部の風車は特に悪天候等の影響を受けやすく、風車の年間稼働率の低下が問題視されている。

このような問題に対し、本研究では、風車の遠隔監視システムである SCADA が収集したデータ（以下、SCADA データ）を活用した風車ブレード雷被害検出手法を提案する。SCADA データを用いて雷撃を受けた風車の健全性を遠隔から自動的に把握できれば、点検のため現地に出向する必要がなくなり、迅速な再稼働とそれによる稼働率の向上が期待できる。本手法では、落雷を受けて停止した風車を出力抑制運転モードで自動的に再稼働すると同時に、異常検知を行うことを提案する。

本研究では、実際に雷被害を受けた風車の SCADA データを分析し、風車雷被害と SCADA データの関係性を調査した。その結果、風車ブレード雷被害検知に資する特徴量が抽出された。次に、これらの特徴量を用いて、機械学習に基づく異常検知モデルを構築し、実際の雷被害を検知可能か検証した。提案手法に基づき、定格運転中の風車の異常検知に加え、出力抑制運転中の風車の異常検知についても検証を行った。

定格運転中の風車を想定した検証の結果、特徴量として風速と回転速度を学習した機械学習モデルにより、AUC および AP が 1.000 の高精度な異常検知を達成した。出力抑制運転中の風車を想定した検証の結果、出力抑制運転状態を異常と認識する傾向にあるものの AUC=0.8 以上の比較的高水準な異常検知精度を実現した。

本研究で得られた知見を活用することで、雷撃を受けた風車ブレードの健全性を遠隔から自動監視できる異常検知システムの実現が期待できる。これにより、停止時間の短縮と稼働率の向上に資する効率的な風車運用が実現できると考えられる。

目次

第1章 序論.....	1
1.1 はじめに.....	1
1.2 風力発電設備の雷被害.....	3
1.2.1 日本の風力発電設備導入量.....	3
1.2.2 風車の雷被害発生状況.....	4
1.2.3 風車雷保護に関する法規制.....	6
1.2.4 雷被害が風車稼働率に及ぼす影響.....	7
1.3 本研究の目的.....	8
1.3.1 提案手法.....	8
1.3.2 本論文の構成.....	9
第2章 風力発電設備と雷.....	10
2.1 風力発電の概要.....	10
2.2 雷の発生.....	12
2.2.1 雷雲の発生と雷放電.....	12
2.2.2 夏季雷と冬季雷.....	14
2.3 雷害対策.....	15
2.3.1 一般的な建築物の雷害対策.....	15
2.3.2 風力発電設備の雷害対策.....	17
2.4 風力発電設備の雷被害分析.....	18
2.4.1 雷被害の分類.....	18
2.4.2 雷被害発生プロセスの分析.....	21
2.4.3 風車雷害対策に関する研究調査.....	23
2.5 雷被害分析に基づく本研究の位置づけ.....	26
第3章 SCADA データと風車雷被害の関係調査.....	27
3.1 SCADA システム.....	27
3.2 SCADA データに基づく風車異常検知.....	28
3.3 風車ブレード損傷事例の分析.....	28
3.3.1 風車 A の事故例分析.....	29
3.3.2 風車 B の事故例分析.....	33
3.3.3 風車 C の事故例分析.....	37
3.3.4 風車 D の事故例分析.....	39
3.3.5 風車 E の事故例分析.....	42
3.4 分析結果のまとめ.....	45
第4章 機械学習モデルに基づく異常検知手法.....	46
4.1 異常検知の概要.....	46

4.2 異常検知手法の種類	47
4.2.1 回帰モデルによる異常検知	47
4.2.2 混合ガウス分布による異常検知	51
4.2.3 オートエンコーダによる異常検知	56
4.3 特徴量の抽出方法	59
4.3.1 基本的特徴量	59
4.3.2 入出力的特徴量	59
4.3.3 正規化パワーカーブ	62
4.3.4 時間的特徴量	64
4.3.5 その他の事前処理	65
4.4 異常検知精度の評価方法	66
4.4.1 混同行列	66
4.4.2 ROC 曲線	67
4.4.3 PR 曲線	69
第5章 風車ブレードの雷被害検出	71
5.1 提案手法の学習・テストプロセス	71
5.2 検証方法と使用データ	72
5.3 検証結果	74
5.3.1 出力抑制運転時の異常検知	74
5.3.2 定格運転時の異常検知	84
5.4 結果についての考察	93
5.4.1 出力抑制運転時の異常検知についての考察	93
5.4.2 定格運転時の異常検知についての考察	99
5.4.3 停止時間短縮効果についての考察	102
第6章 結論と展望	103
6.1 結論	103
6.2 将来の展望	104
謝辞	106
参考文献	107
付録 A	116
A.1 混合分布数 K を 32 とした場合	116
A.2 混合分布数 K を 64 とした場合	118
A.3 混合分布数 K を 128 とした場合	120
A.4 混合分布数 K を 256 とした場合	122
A.5 BIC に基づいて混合分布数 K を決定した場合	124

第1章 序論

1.1 はじめに

低炭素社会の実現に向けた取り組みとして、再生可能エネルギーの普及が進んでいる。The 2023 Conference of the Parties of the UNFCCC (COP28)では、世界の再生可能エネルギー導入容量を2030年までに3倍に増やすという野心的な目標が掲げられ、再生可能エネルギーの存在感はますます強まっている⁽¹⁾。国内でも再生可能エネルギーの主力電源化に向けた取り組みが進められており、経済産業省は国産再生可能エネルギーの普及拡大による技術自給率の向上を目指している⁽²⁾。

再生可能エネルギーの普及が進む中、風力発電事業は特に著しい成長を遂げている。風力発電は再生可能エネルギーの中でも費用対効果が高く、スケールメリットが大きいことで注目されており、洋上風力を含め、各国で大規模な開発が進められている⁽³⁾。国内でも同様の動きが見られ、日本政府は1000万kW規模の洋上風力を2030年までに導入すると宣言している⁽⁴⁾。また、経済産業省が策定した第7次エネルギー基本計画の中で、洋上風力は再生可能エネルギーの主力電源化に向けた「切り札」として位置付けられている⁽²⁾。

一方で、日本は冬季雷による風車の雷被害という特有の問題を抱えており、健全な風力発電事業の発展を妨げることが懸念されている。冬季雷は、日本海沿岸部で多発する現象であり、雷電流の持続時間が長くエネルギーが大きいという特徴を持つ⁽⁵⁻⁷⁾。日本の風車の約4分の1は風況の良い日本海沿岸部に建てられているため、多くの風車が冬季雷の被害を受けている⁽⁷⁻¹⁰⁾。

このような課題を背景に、日本では早期から風車雷被害の低減に向けた法整備が進んできた。風車の雷保護に関する基本的な規制が「発電用風力設備の技術基準の解釈」（以下、風技解釈）である⁽¹¹⁾。この規制は、国内の風車に対して落雷検出装置（Lightning Detection System: LDS）の設置を義務付け、風車への雷撃があれば直ちに運転を停止するよう定めている。この規制により、雷撃で損傷した風車の安全な停止が可能となり、ブレード折損のような深刻な被害は低減された。

しかしながら、落雷検知から再稼働までの点検過程は風車の稼働率を低下させる原因となっており、問題視されている。多くの場合、風車の健全性は電気主任

技術者の指導のもと作業員の目視点検によって確認される。そのため、多くの場合は修繕の可否を問わず作業に時間を要する。悪天候時にはさらに停止時間が長期化し、年間の風車稼働率は大きく低下することとなる⁽¹²⁻¹⁴⁾。また、作業員による目視点検は、風車ブレードの軽微な雷被害を見逃す危険性を孕んでいる。ある風車事故の調査では、LDS が風車への落雷を検知し、安全に運転を停止させたにも関わらず、その後の目視点検で軽微な損傷を発見できずに再稼働させた結果、ブレードの折損を引き起こした事例が報告されている⁽¹⁰⁾。このように、現状の点検方法は即応性と正確性の両面で問題を抱えている。

こうした問題を解決するため、Supervisory Control And Data Acquisition (SCADA) システム^(15, 16)のデータを活用した風車の異常検知手法が多く提案されている⁽¹⁷⁻²⁷⁾。SCADA システムは全ての風車に予め搭載されているため、追加設備を要することなく風車の異常検知を行うことが期待できる。例えば Chen⁽²⁴⁾らは、Long Short-Term Memory (LSTM) と Autoencoder (AE) を組み合わせた異常検知モデルを開発し、実際の風車から収集した多変量 SCADA データを用いて異常検知を行うことに成功している。しかしながら、これらの異常検知手法の主目的は、経年劣化等により発生する風車異常を数か月前から数週間前に予測することであり、落雷のような突発的な事象によって引き起こされる損傷には直接適用できない。そのため、落雷によるブレード損傷の検知に資する特徴量を選定し、その特徴量に適用可能な異常検知モデルを新たに開発する必要がある。

本研究では、風車ブレードの雷被害検出に適用可能な異常検知手法の開発を目指した。まず、過去にブレード損傷事故が発生した風車の SCADA データを分析し、ブレード損傷に関係の深い特徴量を抽出した。また、機械学習モデルに SCADA データを学習させることで、ブレードの健全性を把握することのできる異常検知モデルを構築した。これらの結果に基づき、迅速な再稼働とそれによる稼働率向上を実現するための技術について検討した。

1.2 風力発電設備の雷被害

1.2.1 日本の風力発電設備導入量

風力発電方式は、再生可能エネルギーの中でも特に注目されている。図 1.1 に示したように、日本の風力発電設備導入量は年々増加の傾向にある。日本風力発電協会（Japan Wind Power Association: JWPA）の調べによると、2024 年 12 月時点の累計導入量は 5840 MW にのぼる⁽²⁸⁾。日本全国の風力発電所の位置を図 1.2 に示す。図 1.2 から明らかなように、風車は風況の良い沿岸部に建設されることが多く、その約 4 分の 1 は日本海沿岸部に建設されている。

経済産業省が策定した第 7 次エネルギー基本計画の中では、洋上風力を再生可能エネルギーの主力電源化に向けた「切り札」として位置付けている⁽²⁾。日本政府は浮体式も含む風力発電について、2040 年迄の達成を視野に 30 GW から 45 GW の案件形成を目指している。また、風力発電事業は規模が大きく、産業の裾野が広いと見られ、建築や Operation & Maintenance を通じた雇用創出に資する事業としても期待されている。





図1.1 日本の風力発電設備導入量の推移⁽²⁸⁾




注) 文献⁽²⁹⁾のデータを用いて筆者らが作成

図1.2 日本の風力発電所の所在地⁽²⁹⁾

1.2.2 風車の雷被害発生状況

日本では風車の雷被害が問題視されており、風力発電事業の健全な成長を妨げることが懸念されている。図 1.3 に示す冬季雷地域は、風車が多く建設されている日本海沿岸部と重なっていることが分かる⁽¹¹⁾。最新の風車は最高到達地点が 120 m を上回る⁽³⁰⁻³²⁾ことも少なくなく、周囲に他の建物等が無いことが多いため、風車に落雷が集中しやすい傾向にある^(7,8,33)。そのため、風力発電設備の導入が進む一方で風車の雷被害は数多く報告されており、問題となっている。



注) 地理院地図（電子国土 Web）を一部追記して記載

図1.3 落雷リスクマップ（冬季）⁽¹¹⁾

図 1.4 には，保険請求された日本の風車事故の原因別割合を示した⁽³⁴⁾。これによると，保険事故のうち 54 %が落雷によるものであることが分かる。これは，保険が適用される大きな事故の原因の半数以上が落雷であることを意味している。このように，落雷による風車の損傷は大規模な事故に繋がる危険性が高いため，損傷を早期に検出する技術の開発が必要不可欠である。




図1.4 日本の風力発電設備における保険事故の原因別割合⁽³⁴⁾




図1.5 日本の風力発電設備におけるブレード損傷件数の原因別割合⁽³⁵⁾

風車への落雷を最初に受けるブレードには，被害を防ぐため様々な雷対策が施されているが，雷被害は未だ根絶できていないのが現状である。国内の風車 1,273 基を対象に，2021 年から 2024 年にかけての 3 年間に行われたアンケートの結果によると，落雷が原因と特定されたブレード損傷は 40 件であり，ブレード損傷率

は 0.01 件/基/年であった⁽³⁵⁾。図 1.5 に示す原因別内訳からも明らかなように、損傷全体の 74 %の原因を落雷が占めている。発生件数自体は多くないが、落雷によって損傷したブレードの修繕は容易ではなく、時間的・経済的負担は大きい。

現状、落雷による損傷確率が 0 %のブレードを製作することは現実的でない点にも留意が必要である。放電路に雷電流が流れると、放電路の抵抗値に比例した熱エネルギーが発生するため、ブレードへのダメージを最小限にするためには、放電路の抵抗値を十分に下げる必要がある。しかし、ブレードの主要部を導体にするのは、重量制約の観点から実現不可能である。そのため、風車ブレードの雷被害による経済的な損失を最小限に抑えるためには、落雷を受けたブレードの Operation & Maintenance の効率化が重要である。

1.2.3 風車雷保護に関する法規制

風技解釈は、風車の雷保護に関する基本的な規制がまとめられている⁽¹¹⁾。2014 年頃に落雷による風車の事故が日本全国で急増した⁽¹⁰⁾ことを受け、経済産業省は 2015 年に規制の一部を改正し、冬季雷地域に建設された風車に LDS の設置を義務付けた。その後 2024 年の改正では、冬季雷地域が図 1.3 に示した範囲まで拡張された。さらに、国内全ての風車に LDS の設置が義務付けられ、「風車への雷撃があった場合に直ちに風車を停止することができるように、落雷検出装置等を施設すること」と、内容が改められた。また、この落雷検出装置（LDS）が満たすべき性能も定められ、JIS C 1400-24;2023⁽³⁶⁾に適合することが求められた。

LDS が動作して風車が停止した場合、点検等により設備の健全性が確認できるまで再稼働させることはできない。通常、電気主任技術者の指導のもと作業員が目視点検を行うことにより健全性を確認する。点検方法については「メーカー技術資料等に基づいて設定する」とされており⁽³⁷⁾、具体的な方法はメンテナンス事業者委ねられている。このような属人的な点検からの脱却を目的として、JWPA は点検・補修に関する自主的なルールを策定している⁽³⁸⁾。しかし、これらは法的拘束力を持たないガイドラインとして位置づけられており、制度的な裏付けを有する法規制には至っていないのが現状である。

2024 年には、風車の点検に AI 等のデジタル技術を用いることが法的に認めら

れた。カメラ・ドローンの高性能化や、高精度な画像認識が可能な AI 技術の実現等を受け、経済産業省は「デジタル原則を踏まえた当課所管法令の適用に係る解釈の明確化等について」の中で、「目視による調査，巡視及び点検については，これらの条項の規定上，デジタル技術の活用について明示されていないが，ドローンによる遠隔監視技術の活用や AI による診断など，デジタル技術の活用を妨げるものではない。」と明記している⁽³⁹⁾。こうした側面から見ても，雷撃を受けた風車の異常を遠方から検出する技術の必要性は益々高まっていると言える。

1.2.4 雷被害が風車稼働率に及ぼす影響

現行の風技解釈では，風車への落雷が検知された場合，点検によって健全性が確認されるまで風車を再稼働することができない。悪天候時には目視による点検が困難な場合も少なくないため，この点検過程は風車の停止時間を長期化させ，風車稼働率の低下を招いている。表 1.1 に示すように，雷検知または雷被害が稼働率に大きな影響を及ぼした例も報告されている⁽¹³⁾。なお，表 1.1 は一部抜粋されており，当該ウィンドファームは 29 基の風車があることに注意されたい。

表1.1 雷検知・雷被害が風車稼働率に与える影響（2017 年度）

（文献⁽¹³⁾より引用）

Unit number	Down time	Availability [%]
A	4582 h 20 min	47.7
B	2854 h 12 min	67.4
C	1967 h 53 min	77.5
D	604 h 09 min	93.1
E	293 h 39 min	96.6
Average		95.1

LDS が風車への落雷を検知して運転を停止させた場合でも，実際には損傷を受けていない例も少なくない。この場合，風車は損傷していないにも関わらず，停止時間が発生する。表 1.2 に示すように，故障を伴わない雷検知による停止時間（落雷非故障停止時間）を 12 時間以内に短縮できれば，稼働率が最大 6.76 %向上する例も報告されている⁽¹³⁾。このことから，稼働率の向上を図るためには，落雷検知後の迅速な再稼働が重要であると言える。

表1.2 落雷非故障停止時間を 12 時間に短縮した時の稼働率（2017 年度）
（文献⁽¹³⁾より引用）

Unit number	Actual down time	Assumed down time	Actual availability [%]	Assumed availability [%]	Assumed increase availability [%]
A	604 h 09 min	12 h 00 min	93.1	99.9	6.76
B	1967 h 53 min	1706 h 23 min	77.5	80.5	2.99
C	293 h 39 min	88 h 58 min	96.6	99.0	2.34
D	2854 h 12 min	2681 h 56 min	67.4	69.4	1.97
E	177 h 38 min	12 h 00 min	98.0	99.9	1.89
Average			95.1	96.4	1.28

落雷非故障停止時間は、本来発電できる風車を停止している時間である。そのため、表 1.2 に示された稼働率の想定増加分は逸失と捉えることもできる。風車の設備利用率を 21.5 %と仮定⁽⁴⁰⁾し、当該風車の容量が 1670 kW, 2017 年度の売電価格が 21 円/kWh⁽⁴¹⁾であったことを考慮すると、風車 1 基あたり年間約 84 万円の逸失に相当する。当該ウィンドファームは 29 基の風車があるため、ウィンドファーム全体では年間約 2451 万円の逸失に相当する。この計算例からも明らかなように、風力発電事業の利益最大化のためには、落雷による故障の有無を迅速に判断し、落雷非故障停止時間を最小限に抑えることが重要である。

1.3 本研究の目的

1.3.1 提案手法

本研究では、SCADA データを用いた風車ブレードの雷被害検出手法の開発を目的としている。SCADA データを用いて落雷時のブレードの健全性を把握できれば、落雷検知後の点検を遠隔から自動で行うことができ、迅速な再稼働が可能となる⁽⁴²⁻⁴⁷⁾。

本研究で提案する風車ブレードの雷被害検出手法の概念図を図 1.6 に示す。まず、現行の風技解釈に従い、雷撃を受けた風車は LDS により即座に停止される。その後自動で再稼働が行われ、同時に機械学習モデルに基づく異常検知が実施される。このとき風車は、定格運転ではなく出力を抑制した出力抑制運転で再稼働される。出力抑制運転中に異常が検知されなければ、風車は定格運転に移行し、この間にも異常検知が実施される。




図1.6 風車ブレードの雷被害検出手法の概念図

本研究の提案手法が実現できれば、落雷によって損傷した風車の安全な停止を保障し、かつ、落雷検知後の迅速な再稼働を実現することが期待できる。2015年に発電用風力設備の技術基準の解釈が改定されたことで、落雷によって損傷した風車を安全に停止できるようになった一方、1.2.4項で示した稼働率の問題についての根本的な解決策は未だ確立されていない。本手法は、従来の属人的な点検方法に代わり、落雷を受けた風車の安全かつ迅速な再稼働を可能とする新たな枠組みの構築を目指すものである。

1.3.2 本論文の構成

本論文は以下の6章で構成されている。1章では、風車の導入量と雷被害の現状を説明し、本研究の目的について述べた。2章では、風車と雷現象の概要について説明した後、風車雷被害の発生様相について分析した結果を述べる。3章では、雷被害が報告されている風車のSCADAデータを分析し、SCADAデータと風車雷被害の関係について調査した結果を述べる。4章では、機械学習を用いた異常検知手法の概要について説明し、風車ブレード雷被害検出への適用方法について検討する。5章では、提案手法を実運用SCADAデータに適用し、風車ブレードの雷被害検出を試みた結果を報告する。6章では、本論文の結論について述べる。

第2章 風力発電設備と雷

2.1 風力発電の概要

発電用として最も多く用いられている風車は、図 2.1 に示すような 3 枚翼プロペラ型の水平軸型風車である。(a)は 2 MW 級の陸上風車を、(b)は 9.6 MW 級の着床式洋上風車（ジャケット式）を示している。風車は年を追うごとに大容量化・大型化しており、1980 年代頃には定格出力 750 kW 程度でハブ高さ 20 m 程度であったのに対し、近年は定格出力 2 MW 程度でハブ高さ 70 m、ロータ直径 80 m を超す風車が主流となっている^(30,31,48)。洋上風車は陸上風車よりも大型化の傾向が顕著であり、定格出力 9.6 MW でハブ高さ 110 m、ロータ直径 170 m を超す風車も実用化されている。



(a) 2 MW 級陸上風車



(b) 9.6 MW 級着床式洋上風車

図2.1 3枚翼プロペラ型水平軸型風車の外観

風車が風の流れから取り出して利用できるパワーは、風車のブレード投影面積を通過する運動エネルギーの流れであり、以下の(2.1)式で計算できる⁽⁴⁹⁻⁵¹⁾。

$$P = \frac{1}{2} C_P \rho v_w^3 A \text{ [W]} \quad (2.1)$$

ここで、 C_P は風車のパワー係数、 ρ は空気密度 [kg/m^3]、 v_w は風速 [m/s]、 A はブレード投影面積 [m^2] である。ただし、風車に搭載されている発電機には定格値があるため、定格出力を超えるような定格風速以上の風が吹いている場合、ピッチ制御によって一定の定格出力に保たれる^(48,49)。ピッチ制御は、ブレードピッチが風を受け流す方向に回転することによってブレードを失速させる制御方式である。この制御により風車の風速-発電出力特性（パワーカーブ）は以下の図 2.2 に示した軌跡を描く。図 2.2 から明らかなように、風車はある程度の風速を受けた段階で発電を開始する。この風速をカットイン風速という。定格風速以上になると、ピッチ角制御により出力は一定値に保たれる。強風時には、安全のため風車を停止する。この風速をカットアウト風速という。




図2.2 3 MW 級風車の
パワーカーブ⁽³¹⁾




図2.3 定格運転時と出力抑制運転
時のパワーカーブ

風力発電は定格運転だけでなく、最大出力値 P_{max} を抑制した出力抑制運転を行うことができる。定格運転を行った場合のパワーカーブと、出力抑制運転を行った場合のパワーカーブの例を図 2.3 に示す。図 2.3 から明らかなように、定格運転時は定格風速 15 m/s の時に定格出力 3000 kW を維持するのに対し、出力抑制運転は 1500 kW を超えないよう運転している。出力抑制運転時には、設定された最大出力値 P_{max} に出力 P が近づくと、ピッチ制御により出力が抑制される。出力抑制運転は、運転中の機器振動や温度条件に応じて、一時的に出力を制限する必要があると判断された際に自動で実行される。また、点検時に手動で実行することも可能である。

2.2 雷の発生

2.2.1 雷雲の発生と雷放電

雷雲は積乱雲のうち雷放電（落雷または雲放電）が認められるものと定義され、落雷は激しい対流現象を伴った積乱雲からもたらされる⁽⁵²⁾。雷雲の発生条件の1つは、雲内部で十分な電荷分離が発生する高度まで積乱雲が発達することである。雲が発達すると、雲内では霰を主成分とする降水の形成に伴って電荷分離が発生し、電荷が蓄積される。この電荷を中和する過程の事を雷放電と呼ぶ。

雲内での帯電のメカニズムについては様々な諸説が提案されているが、現在までのところ完全な解明には至っていない。現在最も有力な説は着氷電荷分離機構⁽⁵³⁾であり、氷の結晶と霰の接触によって電荷分離が起こるとされている。このとき、帯電の量と符号は周囲の雲水量と温度によって決まることが明らかとなっている。温度が異なる雲上方と下方でそれぞれ電荷分離すると、電荷分布は以下の図 2.4 に示す 3 重極構造をとる。




図2.4 雷雲内の電荷分布⁽⁵⁴⁾

雷雲に電荷が溜まると、電荷を中和するために落雷（対地雷撃）が起こる。このとき落雷は図 2.5 のように進展する^(7, 52, 55)。まず、部分的な空気の絶縁破壊に

より初期放電が起こり、プラズマチャンネルが形成される。プラズマチャンネルは、 μs オーダーで進展と停止を繰り返しながら空気中を伸びていく。この放電路をステップトリーダと呼ぶ。ステップトリーダの先端が地上に近づき、地上付近の電界が高まると、大地からは結合リーダ（お迎え放電）が伸び始める。ステップトリーダと結合リーダが接すると、雲内から地上までの放電路が繋がり、地面から雷雲に向かってリターンストロークと呼ばれる大電流が流れ、雲内の電荷が中和される。リターンストロークにより放電路の導電性が高まると、雲下部の別の部分からダートリーダが放電路に沿って進展し、地上に到達後、再びリターンストロークを発生させる。このように雷撃が何度も繰り返す現象を多重雷と呼ぶ。





図2.5 落雷の進展過程^(7, 55, 56)

図 2.6 に示すように、落雷は極性や向きによって種類が異なり、「下向き雷」，「上向き雷」，「正極性雷」，「負極性雷」が存在する⁽⁵⁷⁾。この中でも上向き雷は、高構造物に発生しやすいという特徴を持つため、特に注意が必要である。

図2.6 落雷の種類⁽⁵⁷⁾

2.2.2 夏季雷と冬季雷

雷は発生する季節によって夏季雷と冬季雷に大別される。通常、落雷は積乱雲の発生しやすい夏季に多く発生するが、日本海沿岸部では冬季でも落雷が発生する。冬季雷は世界的に見ても珍しい現象であり、日本海沿岸地域以外では北米五大湖東岸やノルウェーなどでも観測される^(7, 52)。

日本海沿岸部の冬季雷には、以下のような特異な性質がある。

- ① 正極性雷の割合が多い。
- ② 電荷量が大きく、放電時間が長い雷が多い。
- ③ 上向き雷が多く、高構造物に雷撃しやすい。
- ④ 夏季雷と比べて雷雲底の高度が低い（図 2.7 参照）

③、④のような特徴を持つため、風車は冬季雷の標的になることが多い。また、②の理由により、大規模な雷被害が数多く報告されている。




図2.7 夏季の雷雲と冬季の雷雲の高度⁽⁵⁸⁾

2.3 雷害対策

2.3.1 一般的な建築物の雷害対策

日本では、高さ 20 m を超える建物に避雷設備を設置することが義務付けられており、日本産業規格（Japanese Industrial Standards: JIS）で定義される雷保護システムが採用されている^(7, 36, 59, 60)。雷保護システムは外部雷保護システムと内部雷保護システムに分類される。

外部雷保護システムは①受雷部システム、②引き下げ導線システム、③接地システムで構成されている。外部雷保護システムの目的は、接近する雷を受雷部システムが確実に捕捉し、雷電流を引き下げ導線システム経由で接地システムから安全迅速に大地に放流することである。これにより、建築物の物的損傷と人畜の生命の危険を防止している。

内部雷保護システムは①等電位ボンディング、②外部雷保護システムの絶縁から成る。等電位ボンディングとは、建物内の金属（鉄骨、鉄筋、手すり、窓枠など）を等電位化することである。内部雷保護システムの目的は、建物への雷撃時に金属部分の過電圧発生を防止することである。

被保護物に雷撃が侵入しないようにするためには、受雷部システムの保護範囲を適切に設計する必要がある。国際電気標準会議（International Electrotechnical Commission: IEC）や JIS では、受雷部システムの保護範囲を計算する方法として

回転球体法を採用している^(36, 60)。図 2.8 に回転球体法の適用例を示す。図 2.8 から明らかなように、2 つ以上の受雷部または 1 つ以上の受雷部と大地に同時に接するように球体を転がした時に、球体表面の包絡面から被保護物側までの範囲が保護範囲となる⁽⁵⁹⁾。球体の半径 R は、想定する雷撃距離によって変化する。図 2.9 に示したように、雷電流波高値が小さくなると雷撃距離も小さくなることが知られている⁽⁶⁰⁾。したがって、小さい落雷の侵入まで防ごうとすると半径 R が小さくなり、保護範囲が狭くなるため、より厳しい条件になる。言い換えると、より厳しい保護レベルが求められる場合には、小さな電流まで対応する必要がある。保護レベルと雷撃距離の関係は表 2.1 に示した。




図2.8 回転球体法の適用例^(36, 59, 60)




表2.1. 雷電流波高値と雷撃距離⁽⁶⁰⁾

Lightning current amplitude [kA]	Striking distance [m]	Lightning Protection Level (LPL)
3	20	I
5	30	II
10	45	III
16	60	IV

図2.9 雷電流波高値と雷撃距離⁽⁶⁰⁾

2.3.2 風力発電設備の雷害対策




図2.10 風力発電設備の雷害対策例^(58, 61)

風力発電設備の雷害対策の基本的な考え方は、2.3.1 項で説明した一般的な建築物の場合と同様である。図 2.10 に風力発電設備の雷害対策例を示す。ブレード先端に設置されたレセプタは、受雷部システムの役割を担う。レセプタとタワーを繋ぐダウンコンダクタと、タワー自体が引き下げ導線システムの役割を担う。また、風車基礎が接地システムの役割を担う。そのほか、ナセルの雷保護を目的とした避雷針や、風車内部の機器の雷害対策を目的としたサージ防護デバイス（Surge Protective Device: SPD）も取り付けられている事が多い。

ブレード上のレセプタの目的は、雷撃を確実に捕捉することにより、ブレード表面への異常着雷を防ぐことである。ブレード表面に着雷すると、表皮を貫通破壊してブレード内部へ侵入する危険性が高く、ブレードが損傷する原因となる。したがって、レセプタの雷捕捉性能を高めることは、ブレードの雷被害を防止する上で極めて重要である。ただし、風車ブレードは回転しているため、レセプタの設計には 2.3.1 項で説明した回転球体法を適用できない。そのため、数値電磁界

解析手法や高電圧放電実験によりレセプタの雷捕捉性能を把握することが推奨されている⁽⁶²⁾。

ダウンコンダクタの目的は、レセプタが捕捉した雷の電流を安全にタワーにまで流し、ブレード内部のアーク発生を防止することである。雷電流によるアークがブレード内部で発生すると、ブレードが致命的な損傷を受ける危険性が高くなる。そのため、断線等の可能性が少ない高耐久なダウンコンダクタを使用することが重要である。また、ダウンコンダクタに絶縁被覆を設けることで、ブレード表面の電界を低減し、レセプタの雷捕捉性能を向上させることができる⁽⁶³⁾。なお、ダウンコンダクタの具体的なサイズ等は IEC⁽⁶⁴⁾で規定されている。

2.4 風力発電設備の雷被害分析

2.4.1 雷被害の分類




図2.11 風力発電設備各部の雷被害^(58, 61)

2.3.2 項で説明した基本的な雷害対策は、現在多くの風力発電設備に導入されているが、風力発電設備の雷被害は未だ根絶できていない。図 2.11 に部位ごとの風力発電設備の雷被害の例を示す。ただし、それぞれの被害が発生する確率と、その被害規模は一様でない点に注意されたい。図 2.11 から明らかなように、多くの部位が雷被害発生リスクを有していることが分かる。

次に、表 2.2 に示す雷被害レベル⁽⁶²⁾を用いて、図 2.11 に示した雷被害を分類する。表 2.2 の雷被害レベルは、公衆安全を害すリスクを定性的に評価するものである。レベル IV が最も重大であり、人の死傷を引き起こす危険性を孕む事故を指す。レベル III はレベル IV に繋がる恐れがあり、迅速な補修を必要とする事故を指す。レベル II は可及的速やかな補修を必要とする事故であり、レベル I は次の定期点検まで補修を必要としない軽微な事象を指す。

表 2.2 の雷被害レベルに従い、図 2.11 の No.1 から No.17 までの雷被害を分類した結果を表 2.3 に示す。表 2.3 では、レベル III 以上の重大な事故を赤字で示した。表 2.3 から明らかなように、レベル III 以上の重大な事故は全てブレードの内外部で発生しており、特にブレードの雷害対策が重要であることが分かる。これらの雷被害様相を図 2.12 に示す。


表2.2. 風車の雷被害レベル⁽⁶²⁾

Damage level	Description
IV	Extremely severe incident that could cause serious injury or death.
III	Serious incident requiring prompt repair to prevent escalation to Level IV.
II	Moderate incident requiring repair as soon as possible.
I	Minor issue that does not require immediate repair until next regular inspection.


表2.3. 雷被害レベル別に分類した風車各部の雷被害

No.	Damage Type	Damage level
1	Melting damage of the receptor	I
2	Burning damage around the receptor	I
3	Scattering of the receptor	II or IV *
4	Melting damage of the down conductor	III
5	Melting damage of the lightning rod	I
6	Burning damage of the anemometer	II
7	Burning damage of the blade surface	I
8	Cracking of the blade	II
9	Debonding of the blade	III
10	Breakage of the blade	IV
11	Scattering of the blade	IV
12	Electrolytic corrosion of the main bearing	I
13	Electrical break down of the generator winding	II
14	Damage of the control equipment	II
15	Damage of the reactor or capacitor	II
16	Damage of the Electric equipment	II
17	Electrical break down of the transformer winding	II

*風車周囲に人が立ち入る恐れがある場合はレベル IV，それ以外の場合はレベル II に分類される。



(a) 落雷によりレセプタが脱落したブレード(No. 3)



(b) 落雷により溶断したダウンコンダクタ(No. 4)



(c) 落雷による損傷が拡大し折損したブレード(No. 9, 10)



(d) 落雷により周囲に飛散したブレード(No. 11)

図2.12 風車ブレードの雷被害の例（文献⁽¹⁰⁾より引用）

2.4.2 雷被害発生プロセスの分析

本項では、表 2.3 に示した雷被害が発生するプロセスについて分析し、それぞれの被害様相に対して有効な雷害対策について検討する。風車への雷雲接近から各雷被害が発生するまでのプロセスを図 2.13 に示す。なお、図 2.13 中の矢印で繋がれた長方形は発生する事象を表しており、雷被害をオレンジで、雷被害が発生しなかった場合を青で示した。また、レベル III 以上の雷被害は赤枠で強調した。矢印の線の太さはその現象が起こる確率を示しており、太い実線は高確率で起こる事象を、実線は中程度の確率で起こる事象を、破線は低確率で起こる事象を、それぞれ示している。




図2.13 風車雷被害の発生プロセスとその対策

図 2.13 から明らかなように、レセプタが雷捕捉に失敗し、ブレードを構成する繊維強化プラスチック（Fiber Reinforced Plastics: FRP）部分に異常着雷があると、高確率でブレードが損傷を受ける。これらの損傷が拡大すると、レベル IV の事故に繋がる危険性がある。また、レセプタが雷捕捉に成功した場合でも、3.レセプタの飛散（レベル II または IV）と 4.ダウンコンダクタの溶断（レベル III）が低確率で発生する危険性があることに留意が必要である。

次に、これらの雷被害に対して有効な雷害対策を青の吹出線で図 2.13 中に示す。これらの雷害対策は、雷被害の発生プロセスを抑制可能なポイントに配置されて

いる。また、これらの雷害対策のうち、風車特有の対策手法に a から k までのアルファベットを付記した。風車特有の雷害対策については 2.4.3 項で解説する。

2.4.3 風車雷害対策に関する研究調査

本項では、図 2.13 に示した風車の雷害対策のうち、風車特有の対策手法に関する研究について調査した結果を報告する。

a. 雷雲接近の予測

風車への雷雲接近を予測し、落雷発生前に運転を停止させる方法である。周辺の大気電界や落雷位置標定システム（Lightning Location System: LLS）の情報に基づいて雷雲接近を行う手法が提案されている^(65,66)。運転中の風車は、停止中と比べて落雷リスクが高まるという調査結果⁽⁶⁷⁾もあり、また、運転中は遠心力によりブレードの雷被害が拡大するリスクもある。落雷発生前に運転を停止させることで、これらのリスクを低減することができる。これにより、ブレード折損などの危険な事故のリスクを低減できる一方、稼働率は低下する。雷雲接近に伴う事前停止を実施すると、稼働率が 4.1 % 低下するという試算結果も報告されている⁽¹⁴⁾。

b. 独立避雷鉄塔の建設

風車周辺に避雷鉄塔を建設することで、風車への落雷を減らす方法である。雷雲の襲来方向がある程度限定されている場合に有効であることが明らかとなっている^(58,68)。一方で建設コストが高く、夏季雷（下向き雷）には雷保護効果が期待できないといった欠点がある。

c. レセプタの雷捕捉精度向上

レセプタの雷捕捉精度を向上させ、ブレードへの異常着雷を防止する方法である。レセプタのサイズ、配置、個数、形状等によって雷捕捉性能が変化することが明らかとなっており、実験的検討・数値解析的検討により、これらを最適化する研究が行われている^(69,70)。2.4.2 項で説明したように、レセプタの雷捕捉が失敗し、FRP 部に異常着雷があると、高確率でブレードが損傷を受ける。そのため、レベル III 以上の事故を防ぐ上でレセプタの雷捕捉精度向上は重要である。

d. レセプタ以外の受雷部システムの実装

レセプタに加え、別種の受雷部システムをブレードに実装する方法である。ダイバーストリップや避雷塗膜などを用いる方法が提案されている^(70, 71)。特に、ダイバーストリップは、レセプタと組み合わせることで雷捕捉精度向上に資することが明らかとなっている。c.レセプタの雷捕捉精度向上と同様、この方法もレベル III 以上の事故を防止する上で重要な技術である。

e.高耐久レセプタの実装

複数回の雷撃を受けても溶損しにくい高耐久なレセプタを実装することで、経年劣化による雷捕捉性能の低下を防ぐ方法である。導電性・熱伝導率が高く、かつ高融点を持つ素材をレセプタの材料に用いることで、冬季雷のようなエネルギーの高い雷を受けても溶損しにくくなることが明らかとなっており、実験的検討や実証実験が行われている^(72, 73)。

f.高耐久ダウンコンダクタの実装

ダウンコンダクタの耐久を向上させることで断線を防止する方法である。ダウンコンダクタが断線すると、雷撃時にブレード内部にアークが発生し、ブレードの損傷に繋がる。そこで、高耐久ダウンコンダクタを実装することにより、断線のリスクを低下させ、ブレードの損傷リスクを抑制できる⁽⁷⁴⁾。

g.ダウンコンダクタの断線検出技術

ダウンコンダクタの断線を早期に検出・修繕することで、ダウンコンダクタの溶損やブレードの損傷を未然に防ぐ方法である。進行波理論を用いる方法、ダウンコンダクタの静電容量を計る方法、高電圧を印加して導通を確認する方法などが提案されている⁽⁷⁵⁻⁷⁷⁾。

h.ブレードの機械的強度向上

ブレードの機械的強度を向上させることで、異常着雷時の貫通破壊防止や、内部アーク発生時のブレード損傷防止を図る方法である。容易に脱落する恐れのない構造のチップレセプタなどが提案されている^(58, 78)。

i. ブレード補修技術の効率化

ブレード補修を効率的に実施し、雷撃を受けて損傷したブレードの健全性を迅速に回復することで、停止時間の低減を図る方法である。今後、AI 技術やロボット等を用いたブレード点検・補修の自動化が期待されている^(79, 80)。また、ブレード補修を行うことで、風車の性能が改善されるという利点もある⁽⁸¹⁾。

j. 損傷の早期検出技術

SCADA データ、状態監視システム（Condition Monitoring System: CMS）のデータ、雷観測カメラの画像データ等を用いて風車ブレードの雷被害を検出することで、雷被害を受けた風車の安全な停止と、落雷後の迅速な再稼働の両立を目指す方法である。本論文の研究成果もこの方法の一つである。

CMS とは、風車の異常兆候の検出を目的に設置されているセンサと観測システムの総称である。振動センサ、回転センサ、電流センサの観測値を高い時間分解能で数時間ごとに記録することができる。また、CMS データを用いた雷被害検出の取り組みとして、LDS と CMS の連携が実施されている⁽⁸²⁾。LDS との連携により、落雷発生時の風車ブレードの振動データを分析することが可能となり、雷被害検出に有効な特徴量の抽出に関する研究が進んでいる^(83, 84)。

高精度な雷観測カメラの一つに、Lightning-eyes[®]がある⁽⁸⁵⁾。Lightning-eyes[®]は風車落雷の映像を捉えることを目的に開発された特殊なビデオカメラであり、風車の輪郭と雷道を明瞭に捉えることが可能である。このカメラの映像を用いて、深層学習モデルに基づく落雷画像認識を行う方法について研究されており、風車落雷の検出や風車ブレード上の着雷位置の推定などが可能になっている⁽⁸⁶⁻⁸⁹⁾。

k. 接地システムのサージインピーダンス低減

雷電流を大地に放流する役割を担っている風車基礎の接地設計を最適化することにより、落雷時の大地電位上昇を抑制する方法である。大地電位の上昇を抑制することにより、風車内部の電気電子機器の破損防止や風車周辺設備への被害波及防止が期待できる。最適な接地構造は、風車の立地や周辺設備の接続状況などによって異なるため、数値電磁界解析等を用いた検討が進められている^(90, 91)。

2.5 雷被害分析に基づく本研究の位置づけ

図 2.13 から明らかなように、j.損傷の早期検出技術の実現により、複数の雷被害シナリオの防止が期待できる。特に、10.ブレードの破損（レベル IV）と 11.ブレードの飛散（レベル IV）を防ぐ手段として有効であると考えられる。また、落雷を受けた風車の目視点検に代わる健全性確認手法としての役割も期待でき、再稼働の迅速化とそれによる稼働率の向上が実現できる可能性もある。このように、本研究の提案手法には高い雷保護効果があると考えられ、複数の雷被害シナリオに対して横断的な予防効果が見込まれる。

第3章 SCADA データと風車雷被害の関係調査

3.1 SCADA システム

SCADA とは，風車の制御に必要な情報を監視・記録するシステムである^(15,16)。記録する情報の種類は風車のメーカーや機種によって異なるが，基本的な要素は多くの風車で共通している。SCADA 項目の一例を表 3.1 に示す。最新のシステムでは 1 秒毎にこれらの情報を記録できるが，データ容量が膨大になるため，10 分値に平均化したデータのみを保存する事業者も少なくない。図 3.1 に正常な風車の SCADA データ（1 分値）の例を示す。

表3.1 SCADA 項目の一例

Parameters of SCADA system
Wind speed [m/s]
Wind direction [°]
Rotational speed [rpm]
Power [kW]
Blade pitch degree [°]
Direction of nacelle [°]




図3.1 SCADA データ（1 分値）の例

3.2 SCADA データに基づく風車異常検知

SCADA データを用いて風車の異常を検知する方法については、これまでも多くの検討がなされている⁽¹⁷⁻²⁷⁾。先行研究によると、風車の各部温度やパワーケーブル、ブレード回転速度などを利用して風車の異常を検知できることが明らかとなっている。SCADA システムはほぼすべての風車に予め設置されているため、これらの手法は追加設備無しで実現できるという利点がある。

しかしながら、既存の手法は風車の定常的な運転データから経年劣化による異常を検出し、故障が発生する数週間前から数か月前に警報することを目的としており、落雷のような突発的な事象により発生するブレード損傷を即座に検出するような方法ではない。SCADA データを用いて風車の雷被害を検出するためには、雷被害と関係の深い特徴量を SCADA から抽出する必要がある。

3.3 風車ブレード損傷事例の分析

本節では、実際に雷被害を受けた風車の SCADA データを分析することにより、雷被害検出に有効な特徴量の抽出を試みた結果について述べる。表 3.2 に研究対象の風車の一覧と、それぞれの事故の概要、原因となった落雷のデータを示す。表 3.2 から明らかなように、風車 E の事故を除いた 4 件の事故は、冬季雷地域にある風車で発生しており、いずれも落雷が原因である。なお、事故発生時、風車 D には LDS が設置されていたが、その他の風車には設置されていなかった。そのため、風車 A, B, C への落雷の発生時刻と電流最大値は、フランクリンジャンプの全国雷観測ネットワークによる LLS のデータに基づいて推定した。風車 D については、周波数帯域 0.1 Hz～ 1 MHz を有する LDS（東光高岳製）で記録されたデータを用いた。

調査対象とした SCADA データの観測期間を表 3.3 に示す。まず、落雷のあった時刻の前後に観測された SCADA データを分析し、落雷前後で顕著な変化が確認できないか検証した。なお、落雷時刻を含む期間のうち、データの記録が残っていた期間について分析を行った。次に、事故以前または修繕後に長期間観測された正常運転時の SCADA データと、落雷後の SCADA データを比較した。

表3.2 ブレード損傷事故の概要と事故の原因と考えられる落雷のデータ

Name of wind farm	Area	Lightning data*		Automatic stop	Condition after the lightning strike
		Maximum current [kA]	Electric charge [C]		
Wind turbine A	Tōhoku (Sea of Japan coast area)	45 kA	Not available	Not available	Breakage of the blade
Wind turbine B	Hokuriku (Sea of Japan coast area)	-31 kA	Not available	Not available	Scattering of the tip receptor
		27 kA			
		12 kA			
		-14 kA			
		-7 kA			
		73 kA			
		11 kA			
		-14 kA			
		238 kA			
Wind turbine C	Tōhoku (Sea of Japan coast area)	87 kA	Not available	Available	Breakage of the blade
Wind turbine D	Tōhoku (Sea of Japan coast area)	19 kA	328 C	Available	Breakage of the blade (after restart)
Wind turbine E	Tōhoku				

*Wind turbine D への落雷についてのデータは、0.1 Hz-1MHz の周波数帯域を持つ LDS の測定値に基づいている。


また、その他の風車への落雷についてのデータは、フランクリンジャパンの LLS データに基づいている。

表3.3 調査対象の SCADA データの時間分解能と観測期間

Name of wind farm	Type of SCADA data	Pre-/Post-accident data duration	Normal operation data duration
Wind turbine A	1-min average data	171 min (171 plots)	Approximately 23 days (34139 plots)
Wind turbine B	1-min average data	Approximately 15 days (21543 plots)	Approximately 28 days (40384 plots)
Wind turbine C	1-min average data	217 min (217 plots)	Approximately 23 days (34125)
Wind turbine D	10-min average data	Approximately 13.5 days (509 plots)	Approximately 52 days (7556 plots)
Wind turbine E	10-sec average data	Approximately 899 min (5395 plots)	Approximately 6 days (7556 plots)

3.3.1 風車 A の事故例分析

風車 A は冬季雷地域（日本海側の東北地域）に建設された風車である。風車 A 周辺の風速分布を図 3.2 に示す。なお、図 3.2 はワイブル分布⁽⁹²⁾で近似した値を示しており、ワイブル分布の定数は文献⁽⁹³⁾を参照して設定した。



注) 文献⁽⁹³⁾を基に筆者らが作成

図3.2 風車 A 周辺の風速分布⁽⁹³⁾

風車 A では、落雷によりブレードが折損する事故が報告されている。事故後に行われた調査の結果、折損の原因となった落雷は運転中の風車ブレードに直撃していたことが明らかとなった。しかし、事故当時の風車に LDS は設置されていなかったため、落雷の直撃にも関わらず風車は運転を継続した。その結果、回転の遠心力で落雷による損傷が徐々に拡大し、落雷から約 20 分後にブレードの折損に至ったと推測されている。

この時の落雷前後の SCADA データ（1 分値）を示したグラフを以下の図 3.3 に示す。図 3.3 から明らかなように、この例では、ただ単純に各 SCADA データの時間特性を観察しても、異常兆候を発見することはできなかった。




図3.3 風車 A の落雷前後の SCADA データ（1 分値）

そこで、風車の入出力の関係に注目した分析を行った。ここでは、入力の情報として風速を、出力の情報として回転速度と発電出力を選択し、これらの入出力特性を観察することでブレード異常を検知できないか検討した。図 3.4 に落雷前後と正常運転時の風速-回転速度特性と風速-発電出力特性を示す。なお、落雷前と落雷後でプロットの種類を分けて比較を行った。青は落雷前のデータ、赤は落雷後のデータ、緑は正常運転時のデータである。また、黒枠で囲んだデータは全体の傾向から外れた値（以後、外れ値と呼称）である。




図3.4 風車 A の SCADA データ比較図（1 分値）

図 3.4 より、落雷後のデータには、外れ値が多く発生していることが分かる。ただし、この外れ値は正常運転時にも発生している。外れ値が正常運転時に発生したものなのか、異常性を持つものなのかを区別できれば、落雷によるブレード損傷を検知できると考えられる。

次に、外れ値の出現頻度に着目して分析を行った。落雷前後の回転速度の時間変化と、正常運転時の回転速度を図 3.5 で比較する。なお、図 3.5 の時間変化は、

データ観測開始時刻を 0 とした相対時間で示した。




図3.5 風車 A の風速-回転速度特性とその時間特性（1 分値）

図 3.5 (d)からも明らかなように、正常運転時に発生した外れ値は、1 回あるいは 2 回発生した後に正常値に回復しており、連続して 3 回以上続いている。一方、図 3.5 (c)からも明らかなように、落雷後には連続して外れ値が発生している。この結果より、外れ値の発生を検知し出現頻度を確認することで、ブレードの異常を検知できる可能性が高いことが分かる。

次に、落雷後の風速-回転速度特性と風速-発電出力特性に現れた外れ値の発生原因について考察する。風車の回転速度はブレードに作用する揚力 L によって決まる。 L は以下の(3.1)式で求めることができる⁽⁵⁰⁾。

$$L = \frac{1}{2} C_L \rho v_w^2 A \text{ [N]} \quad (3.1)$$


ここで、 C_L はブレードの揚力係数、 ρ は空気密度 $[\text{kg/m}^3]$ 、 v_w は風速 $[\text{m/s}]$ 、 A は

ブレード投影面積[m²]である。揚力係数 C_L はブレードの形状によって変化するため、雷撃によりブレードに亀裂や貫通穴が生じると、設計値よりも値が小さくなると考えられる。すると(3.1)式より、同じ ρ , v_w , A に対して揚力 L は小さくなり、その結果として回転速度も下がることが分かる。図 3.5 (c)より、落雷後は回転速度が低い状態が続いており、かつ、図 3.5 (a)からも、ブレードの揚力係数が低下した様子が確認できる。また、回転速度の低下に伴い、発電出力も低下したため、風速-発電出力特性にも外れ値が生じたと考えられる。

以上の分析結果より、この事故例ではブレード異常に起因した外れ値が SCADA データに現れていることから、SCADA データを用いた異常検知により事故を防げた可能性は高いと言える。

3.3.2 風車 B の事故例分析

風車 B は冬季雷地域（北陸地域）に建設された風車である。風車 B 周辺の風速分布を図 3.6 に示す。なお、図 3.6 はワイブル分布⁽⁹²⁾で近似した値を示しており、ワイブル分布の定数は文献⁽⁴¹⁾を参照して設定した。



注) 文献⁽⁹³⁾を基に筆者らが作成

図3.6 風車 B 周辺の風速分布⁽⁹³⁾

風車 B では、落雷によりチップレセプタが脱落する事故が報告されている。事故後に行われた調査の結果、レセプタ脱落の原因となった落雷はブレード表皮を貫通してダウンコンダクタへ直接侵入していたことが明らかとなった。この時、ブレード先端内部でアークが発生し、内部空気の膨張によりチップレセプタとブ

レードを繋ぐ接着部が破損したと推定されている。しかし、事故当時の風車に LDS は設置されていなかったため、風車は運転を継続した。その結果、回転の遠心力によりチップレセプタとダウンコンダクタ間の接続が完全に外れ、レセプタが周囲に飛散した。LLS のデータによると、事故発生前のメンテナンス時にブレードの健全性が確認されてから、臨時点検によりレセプタ脱落が認められるまでの間、風車を中心とした半径 3 km 以内の範囲に 9 回の落雷が観測されている。これらの落雷のうち、どの落雷がブレードに致命的な損傷を与えたかは判明していない。

この時の落雷前後の SCADA データ（1 分値）を示したグラフを以下の図 3.7 に示す。図 3.7 から明らかなように、風車 A での事故の分析結果と同様、各 SCADA データの時間特性から異常兆候を発見することはできなかった。




図3.7 風車 B の落雷前後の SCADA データ（1 分値）

そこで同様に、風車の入出力の関係に注目した分析を行った。ここでは、入力として風速を、出力の情報として回転速度、発電出力、ピッチ角を選択し、これらの入出力特性を観察することでブレード異常を検知できないか検討した。図 3.8 に落雷前後と正常運転時の風速-回転速度特性、風速-発電出力特性、風速-ピッチ角特性を示す。なお、落雷前と落雷後でプロットの種類を分けて比較を行った。青は落雷前のデータ、赤は落雷後のデータ、緑は正常運転時のデータである。また、黒枠で囲んだデータは外れ値である。




図3.8 風車 B の SCADA データ比較図 (1 分値)


図 3.8 より，風車 A の事例と同様，落雷後のデータには外れ値が多く発生していることが分かる。また，同時刻の風速-ピッチ角特性にも外れ値が生じていることが明らかとなった。ただし風車 A と同様に，この外れ値は正常運転時にも発生していることが分かる。外れ値が正常運転時に発生したものなのか，異常性を持つものなのか区別できれば，落雷によるブレード損傷を検知できると考えられる。

また，図 3.8 から明らかなように，当該風車は落雷後に出力抑制運転を行っていたことが分かる。正常運転時には定格運転を行う事が多いため，落雷後の特性と正常運転時の特性が重なっていないことには留意する必要がある。


次に，外れ値の出現頻度に着目して分析を行った。落雷前後の回転速度の時間変化と，正常運転時の回転速度の時間変化を図 3.9 で比較する。なお，図 3.9 の時間変化は，データ観測開始時刻を 0 とした相対時間で示した。

図 3.9 から明らかなように，正常時にも外れ値は多く発生しているが，落雷直後と比べて頻度は低い。したがってこの例では，外れ値の出現頻度を確認すれ


ば落雷直後のブレード異常を検知できた可能性が高い。また、図 3.9 (b)から明らかなように、14000 min 付近から外れ値が高頻度かつ集中して発生していることから、この時刻付近でブレードが深刻なダメージを受けた可能性が高い。




(a) 風速-回転速度特性




(b) 回転速度の時間特性（落雷前後）



(c) 回転速度の時間特性（正常時）



(d) 回転速度の時間特性
(落雷前後拡大)



(e) 回転速度の時間特性
(正常時拡大)

図3.9 風車 B の風速-回転速度特性とその時間変化（1 分値）

次に、落雷後の風速-ピッチ角特性に現れた外れ値の発生原因について考察する。これらの外れ値の発生は、風車の制御系に起因していると考えられる。図 3.10 に

示すように、通常、ピッチ角は発電出力 P が最大発電出力 P_{max} を超えないよう制御される⁽⁵⁰⁾。図 3.8(b)からも明らかなように、同時刻の風速-発電出力特性にも外れ値が発生しているため、これがピッチ角に外れ値を生じさせたと考えられる。





図3.10 風車の制御システム⁽⁵⁰⁾

以上の分析結果より、この事故例ではブレード異常に起因した外れ値が SCADA データに現れていることから、SCADA データを用いた異常検知により事故を防げた可能性は高いと言える。

3.3.3 風車 C の事故例分析

風車 C は冬季雷地域（日本海側の東北地域）に建設された風車である。風車 C 周辺の風速分布を図 3.11 に示す。なお、図 3.11 はワイブル分布⁽⁹²⁾で近似した値を示しており、ワイブル分布の定数は文献⁽⁴¹⁾を参照して設定した。



注) 文献⁽⁹³⁾を基に筆者らが作成

図3.11 風車 C 周辺の風速分布⁽⁹³⁾

風車 C では、落雷によりブレードが折損する事故が報告されている。事故後に行われた調査の結果、落雷が風車ブレードを直撃したことが明らかとなった。事

故当時の風車に LDS は設置されていなかったが、落雷により風車内で低圧地絡が検知されたため、風車は落雷から 20～30 秒後に自動停止した。しかし、風圧によってブレードが裂け、風車停止動作中または停止後まもなく損傷が拡大し、折損に至ったと推定されている。

この時の落雷前後の SCADA データ（1 分値）を示したグラフを以下の図 3.12 に示す。図 3.12 から明らかなように、他の分析結果と同様、各 SCADA データの時間特性から異常兆候を発見することはできなかった。




図3.12 風車 C の落雷前後の SCADA データ（1 分値）

そこで同様に、風車の入出力の関係に注目した分析を行った。ここでは、入力の情報として風速を、出力の情報として回転速度と発電出力を選択し、これらの入出力特性を観察することでブレード異常を検知できないかを検討した。図 3.13 に落雷前後と正常運転時の風速-回転速度特性と風速-発電出力特性を示す。なお、落雷前と落雷後でプロットの種類を分けて比較を行った。青は落雷直前のデータ、赤は落雷直後のデータ、緑は正常運転時のデータである。




図3.13 風車 C の SCADA データ比較図 (1 分値)


図 3.13 から明らかなように、落雷前後に外れ値は発生していない。この例では落雷後すぐに自動停止したため、ブレード異常に起因した外れ値が観測されなかったと考えられる。このように、落雷直後に風車を停止させたにも関わらず、ブレードが破損するような事故の場合、SCADA データを用いた異常検知は困難であると考えられる。

以上の分析結果より、この事故例ではブレード異常に起因した外れ値が SCADA データに現れていないため、SCADA データを用いた異常検知によって事故を防ぐことは困難である。

3.3.4 風車 D の事故例分析

風車 D は冬季雷地域（日本海側の東北地域）に建設された風車である。風車 D 周辺の風速分布を図 3.14 に示す。なお、図 3.14 はワイブル分布⁽⁹²⁾で近似した値を示しており、ワイブル分布の定数は文献⁽⁴¹⁾を参照して設定した。

風車 D では、落雷によりブレードが折損する事故が報告されている。この事故の場合、事故当時の風車に LDS が設置されていたため、風車への落雷により運転は一度停止されていた。しかし、地上からの目視点検で異常が認められなかったため、運転を再開した結果、約 47 時間後にブレードが折損した。事故後に行われた調査の結果、ブレード内部に複数のアーク痕が生じていたことが明らかとなった。約 47 時間の運転による負荷で落雷による損傷が徐々に拡大し、折損に至ったと推定されている。



注) 文献⁽⁹³⁾を基に筆者らが作成

図3.14 風車 D 周辺の風速分布⁽⁹³⁾

この時の落雷前後の SCADA データ（10 分値）を示したグラフを以下の図 3.15 に示す。図 3.15 から明らかなように、他の分析結果と同様、各 SCADA データの時間特性からは異常兆候を発見することはできなかった。




図3.15 風車 D の落雷前後の SCADA データ（10 分値）

そこで同様に、風車の入出力の関係に注目した分析を行った。ここでは、入力として風速を、出力の情報として回転速度、発電出力、ピッチ角を選択し、これらの入出力特性を観察することでブレード異常を検知できないか検討した。図 3.16 に落雷前後と正常運転時の風速-回転速度特性、風速-発電出力特性、風速-ピッチ角特性を示す。なお、落雷前と落雷後でプロットの種類を分けて比較を行った。青は落雷前のデータ、赤は落雷後のデータ、緑は正常運転時のデータであ

る。また、黒枠で囲んだデータは外れ値である。





図3.16 風車 D の SCADA データ比較図（10 分値）

図 3.16 から明らかなように、落雷後のデータにはいくつかの外れ値が出現している。しかしながら、他の事故例で見られた高頻度かつ集中した外れ値の発生は確認できない。風車 D は SCADA の 1 分値が記録されていないため、10 分値を使って検証している。そのため、1 分値を平均化して 10 分値にする過程で外れ値が丸められ、顕著に現れなくなつたと考えられる。

図 3.17 は、風車 A の SCADA データを 10 分値に変換し、風速-回転速度と回転速度の時間変化を示したグラフである。SCADA データの 1 分値から、落雷による風車 A のブレード異常を検知できることは既に説明した。しかしながら、図 3.5 と図 3.17 を比較すると、10 分値では外れ値が高頻度かつ集中して発生した状況が確認できないことが分かる。したがって、SCADA データから落雷によるブレード損傷を検知する場合、少なくとも 1 分値が必要であると考えられる。




(a) 回転速度の時間特性（落雷前後） (b) 回転速度の時間特性（正常時）

図3.17 風車 A の SCADA データ比較図（10 分値）

3.3.5 風車 E の事故例分析

風車 E は東北地域の太平洋側山間部に建設された風車である。風車 E 周辺の風速分布を図 3.18 に示す。なお、図 3.18 はワイブル分布⁽⁹²⁾で近似した値を示しており、ワイブル分布の定数は文献⁽⁴¹⁾を参照して設定した。



注) 文献⁽⁹³⁾を基に筆者らが作成

図3.18 風車 E 周辺の風速分布⁽⁹³⁾

風車 E ではブレードが損傷する事故が発生している。事故後に行われた調査の結果、事故の原因は無負荷時の制御異常による過回転であることが明らかとなった。この事故が発生する数十分前に、停電により風車から負荷が遮断されていた。このような場合、通常ブレードの回転は自動的に停止するよう制御されている。しかし、この時はブレードピッチが動作せず、過回転が発生した。その結果、定格を超える遠心力がブレードに加わり、折損に至った。当該事故の原因は落雷で

はないが、通常の雷被害と同様にブレードが突発的に損傷した事象であるため、検討対象として十分な重要性を有すると判断した。

この時の落雷前後の SCADA データ（10 秒値）を示したグラフを以下の図 3.19 に示す。なお、青い枠線で過回転発生前を、赤い枠線で過回転発生時をそれぞれ囲った。図 3.19 から明らかなように、他の風車とは異なり、風速、回転速度、発電出力、ピッチ角といったパラメータが非連続的に変化していることが確認できる。このことから、データ取得の段階で既に異常が生じている可能性が高い。





図3.19 風車 E の落雷前後の SCADA データ（10 秒値）


この例でも同様に、風車の入出力の関係に注目した分析を行った。ここでは、入力の情報として風速を、出力の情報として回転速度、発電出力、ピッチ角を選択し、これらの入出力特性を観察することでブレード異常を検知できないか検討した。図 3.20 に過回転発生前後と正常運転時の風速-回転速度特性、風速-発電出力特性、風速-ピッチ角特性を示す。なお、過回転発生前と発生後でプロットの種類を分けて比較を行った。青は過回転発生前のデータ、赤は過回転発生後のデータ、緑は正常運転時のデータである。

図 3.20 から明らかなように、他の風車と明らかに異なった特性を描いている。特に、風速が 10 m/s より低い領域では、回転速度とピッチ角が制御できていないことが分かる。この現象は事故発生時だけでなく、正常運転時でも同様に発生しているため、長期間に渡って適切なデータ取得ができない状態であったと考えら


れる。本来、風車が無負荷になれば、風速に応じてピッチ角を制御して過回転を防ぐ必要があるが、風速データにこのような不具合が生じていたために、過回転を抑制できなかったと考えられる。



(a) 風速-回転速度特性



(b) 風速-発電出力特



(c) 風速-ピッチ角特性

図3.20 風車 E の SCADA データ比較図 (1 分値)

以上の分析結果より、この事故例では、過回転の原因と推定される故障が SCADA データに直接現れているため、SCADA データを監視・分析することで事故発生を防げていた可能性が高い。

3.4 分析結果のまとめ

3.3 節で分析した事故例の検証結果を以下の表 3.4 にまとめる。表に示したように、5 件の事故のうち 4 件は、SCADA データの監視・分析によって未然に防げていた可能性があることが明らかとなった。ただし、少なくとも 1 分値が必要である。また、風車 C の事故のように、落雷直後の風車停止で防げないブレード損傷の場合、SCADA データを用いた異常検知は困難であると考えられる。

表3.4 SCADA データを用いた異常検知の実現可能性

Name of wind farm	Can the accidents was prevented by analysing SCADA data ?	Type of SCADA	The characteristics in which the outlier appeared
Wind turbine A	Yes	1-min average data	wind speed-rotatinal speed, wind speed-power
Wind turbine B	Yes	1-min average data	wind speed-rotatinal speed, wind speed-power, wind speed-pitch degree
Wind turbine C	No	1-min average data	
Wind turbine D	Unclear	10-min average data	wind speed-rotatinal speed, wind speed-power, wind speed-pitch degree
Wind turbine E	Yes	10-sec average data	wind speed-rotatinal speed, wind speed-power, wind speed-pitch degree

3.3 節の分析で得られた考察は以下の通りである。

1. 風車ブレードの雷被害検出に有効であると考えられる特徴量は、風速、回転速度、発電出力、ピッチ角といったパラメータである。
2. 風速-回転速度特性、風速-発電出力特性、風速-ピッチ角特性に生じる外れ値と、その出現頻度を確認することで、ブレード損傷を検知できる可能性が高い。
3. 外れ値を検知するためには、少なくとも 1 分値が必要である。

以上の結果を元に、第 4 章以降では機械学習を用いてブレード損傷を自動検知する方法について検討する。

第4章 機械学習モデルに基づく異常検知手法

4.1 異常検知の概要

異常検知とは、あるデータを正常または異常に分類するタスクである。ただし、注意しなければならないのは、異常データの数と正常データの数と比べて非常に少ないということである。したがって、正常と異常の特徴を把握して分類するやり方は現実的ではない。一般的には、以下のようなステップで異常を検知する方法が広く使われている。

1. ばらつきを考慮した正常データの分布をモデル化する。
2. 正常からのずれの度合を異常度として定義する。
3. 異常度が閾値より大きい場合を異常、小さい場合を正常と判定する。

このやり方であれば、モデル化するのは正常データだけで済むため、大量の正常データがあれば異常検知が可能である。

図4.1はあるデータに対して異常検知を実行した例を示している。図4.1 (a)は正常データと異常データである。この正常データの密度を基に分布をモデル化したのが図4.1 (b)である。図4.1 (b)の確率モデルに閾値を設け、ある程度正常から乖離したら異常と判定すれば、異常検知が可能となる。




図4.1 異常検知の実行例

機械学習に基づく異常検知手法には多くの種類があるが、本研究では混合ガウス分布（Gaussian Mixture Model: GMM）を用いた方法と、オートエンコーダ（AutoEncoder: AE）を用いた方法を使用した。また、SCADA データから特徴量を抽出する過程では、回帰モデルを用いた方法を補助的に利用している。GMM は、正常データの確率分布を推定することにより、発生する確率の低い外れ値を検知する方法である。AE は、ニューラルネットワークを用いて正常データの部分空間を推定し、部分空間から離れた外れ値を検知する方法である。第3章で示した分析結果より、落雷により風車が損傷すると SCADA データから外れ値が多く発生することから、外れ値を検知できるこれらの手法は有効であると考えられる。

4.2 異常検知手法の種類

4.2.1 回帰モデルによる異常検知

入力と出力があるデータから異常検知を行う場合は、回帰を用いた異常検知手法が有効である⁽⁹⁴⁾。このようなデータの場合、与えられた入力に対して出力を眺め、それが通常の振る舞いから期待される値から大幅にずれているかどうかを見るのが自然である。そこで、入出力特性を予め回帰しておき、回帰式によって予測された出力と実際の出力との誤差が大きければ異常と判別すれば、異常検知が可能である。




図4.2 線形回帰モデルを用いた異常検知の実行例

図 4.2 は入出力の関係にある特徴量 x と y に対し、線形回帰モデルを用いて異常検知を行う例である。図 4.2 (a)に示した正常データを 1 次式で近似する場合、以下の(4.1)式に示す平均二乗誤差 J が最小になる係数 a , b を選択する必要がある。最小二乗法を用いれば、 a と b を(4.2)式で計算することができる。これにより、正常データの振る舞いを近似した一次式が得られる。異常検知を行う場合は、図 4.2 (b)に示したように、一次式と未知のデータの二乗誤差を計算する。この二乗誤差を異常度として定義し閾値を設ければ、データを正常と異常に分類できる。

本研究では、二乗誤差を直接異常度として用いるのではなく、他の異常検知手法の特徴量として用いた。この特徴量の詳細については、4.3.2 項で述べる。

$$J = \sum_{i=0}^{N-1} \{y_i - (ax_i + b)\}^2 \quad (4.1)$$

$$\begin{cases} a = \frac{\sum_{i=0}^{N-1} \{(x_i - \bar{x})(y_i - \bar{y})\}}{\sum_{i=0}^{N-1} \{(x_i - \bar{x})^2\}} \\ b = \bar{y} - a\bar{x} \end{cases} \quad (4.2)$$




図4.3 サポートベクター回帰の実行例

図 4.3 はサポートベクター回帰（Support Vector Regression: SVR）の実行例である。まず、ある多次元変数 $\mathbf{x}$ を線形回帰すると、(4.3)式に示すような超平面関数 $f(\mathbf{x})$ が得られる。この時、 $\mathbf{w}$ は重み係数ベクトルを表す。

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b \quad (4.3)$$

ここで、予測値 $f(\mathbf{x})$ と真の値の差を r と定義する。ちなみに、この残差 r が最小となる $\mathbf{w}$ と b を計算するのが最小二乗法である。SVR では、正の小さな値 ε を用いて、以下の(4.4)式で誤差 E を定義する。

$$E = \begin{cases} 0 & (|r| \leq \varepsilon) \\ |r| - \varepsilon & (\text{上記以外}) \end{cases} \quad (4.4)$$

(4.4)式より、 $f(\mathbf{x}) \pm \varepsilon$ のなかに真の値が入れば、誤差 E は 0 として計算される。この $f(\mathbf{x}) \pm \varepsilon$ を ε チューブと呼ぶ。また、 ε は不感度係数と呼ばれ、SVR のハイパーパラメータである。全てのデータ点 $(\mathbf{x}, y)$ がこの ε チューブ内に収まるとすれば、 $y = f(\mathbf{x}) \pm \varepsilon$ を満たす点が最も超平面から遠い点となる。この超平面からの距離をマージンと呼ぶ。このマージンを最大化すれば、未知のデータがマージン内に入る可能性が高くなり、汎化性能を最大にすることができる。マージンを最大化するためには、以下の(4.5)式に示す 2 次計画問題を解けば良いことが知られている⁽⁹⁵⁾。

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}\| \\ \text{s.t.} \quad & y_n - \mathbf{w}^T \mathbf{x}_n - b \leq \varepsilon \quad (n=0, 1, 2, \dots, N) \\ & \mathbf{w}^T \mathbf{x}_n - b - y_n \leq \varepsilon \quad (n=0, 1, 2, \dots, N) \end{aligned} \quad (4.5)$$

(4.5)式では、全ての学習データが ε チューブ内に収まることを想定しているが、 ε チューブの外にデータの存在を許すには、 $\mathbf{x}_n$ に対して以下の(4.6)式、(4.7)式で定義されるスラック変数 ξ_n 、 ξ_n^* を導入する必要がある。

$$\xi_n = \begin{cases} 0 & (y_n - f(\mathbf{x}_n) - \varepsilon \leq 0) \\ y_n - f(\mathbf{x}_n) - \varepsilon & (\text{上記以外}) \end{cases} \quad (4.6)$$

$$\xi_n^* = \begin{cases} 0 & (\varepsilon + y_n - f(\mathbf{x}_n) \geq 0) \\ -\varepsilon - \{y_n - f(\mathbf{x}_n)\} & (\text{上記以外}) \end{cases} \quad (4.7)$$

スラック変数はデータが ε チューブからどれだけ離れているかを意味しており、これを最小化させる必要がある。したがって、SVR は以下の(4.8)式で最適化できる。

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}\| + C \sum_{n=0}^N (\xi_n + \xi_n^*) \\ \text{s.t.} \quad & y_n - \mathbf{w}^T \mathbf{x}_n - b \leq \varepsilon \quad (n=0, 1, 2, \dots, N) \end{aligned} \quad (4.8)$$

$$\mathbf{w}^T \mathbf{x}_n - b - y_n \leq \varepsilon \quad (n=0, 1, 2, \dots, N)$$

$$\xi_n \geq 0, \quad \xi_n^* \geq 0$$

ここで、 C は正則化係数であり、マージン最大化と誤差の最小化のバランスを決める SVR のハイパーパラメータである。ラグランジュの未定乗数法⁽⁹⁶⁾を用いると、(4.8)式の条件付き最小化問題は以下の(4.9)式で表せる。

$$\begin{aligned} L = & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=0}^N (\xi_n + \xi_n^*) - \sum_{n=0}^N (\mu_n \xi_n + \mu_n^* \xi_n^*) \\ & - \sum_{n=0}^N a_n (\varepsilon + \xi_n + f(\mathbf{x}_n) - y_n) - \sum_{n=0}^N a_n^* (\varepsilon + \xi_n^* + f(\mathbf{x}_n) - y_n) \end{aligned} \quad (4.9)$$

なお、(4.9)式中の a_n , a_n^* , μ_n , μ_n^* はラグランジュ乗数である。(4.9)式の $f(\mathbf{x})$ を(4.3)式に置き換え、 $\mathbf{w}$, b , ξ_n , ξ_n^* に対して微分をすれば、以下の(4.10)式から(4.13)式が得られる。

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{n=0}^N (a_n - a_n^*) \mathbf{x}_n \quad (4.10)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{n=0}^N (a_n - a_n^*) = 0 \quad (4.11)$$

$$\frac{\partial L}{\partial \xi_n} = 0 \rightarrow a_n + \mu_n = C \quad (4.12)$$

$$\frac{\partial L}{\partial \xi_n^*} = 0 \rightarrow a_n^* + \mu_n^* = C \quad (4.13)$$

これらの式を用いて(4.9)式を変形すると、以下の(4.14)式に示すような a_n と a_n^* に対する最大化問題に帰着する。

$$L = -\frac{1}{2} \sum_{n=0}^N \sum_{m=0}^N (a_n - a_n^*)(a_m - a_m^*) \mathbf{x}_n^T \mathbf{x}_m - \varepsilon \sum_{n=1}^N (a_n + a_n^*) \sum_{n=1}^N (a_n - a_n^*) y_n \quad (4.14)$$

また、ラグランジュ乗数が 0 以上である事と、(4.12)式と(4.13)式から、以下の条件式(4.15)が成り立つ。

$$\begin{cases} 0 \leq a_n \leq C \\ 0 \leq a_n^* \leq C \end{cases} \quad (4.15)$$

結果として、(4.14)式に対して(4.11)式と(4.15)式が条件として付いた2次計画問題に帰着する。この2次計画問題の解法には、分割法やニュートン法を用いた数値解法が用いられている⁽⁹⁵⁾。

(4.10)式を(4.3)式に代入すると、以下の(4.16)式に変形できる。(4.16)式は $\mathbf{x}$ とその転置の内積があれば計算できることが分かる。

$$f(\mathbf{x}) = \sum_{n=1}^N (a_n - a_n^*) \mathbf{x}^T \mathbf{x}_n + b \quad (4.16)$$

(4.16)式からも明らかなように、SVRは線形で近似できるデータに対し有効である。非線形の特徴を持つデータに対し適用するためには、カーネルトリック⁽⁹⁵⁾と呼ばれる手法が必要になる。まず、非線形なデータ $(\mathbf{x}, y)$ を線形な高次元データ $(\phi(\mathbf{x}), y)$ に変換できる写像 ϕ を考える。この $\phi(\mathbf{x})$ を用いてSVRを行うと、(4.16)式より以下の(4.17)式が成り立つ。

$$f(\phi(\mathbf{x})) = \sum_{n=1}^N (a_n - a_n^*) \phi(\mathbf{x})^T \phi(\mathbf{x}_n) + b \quad (4.17)$$

(4.17)式からも明らかなように、SVRの計算に必要なのは、写像 ϕ そのものではなく、その内積 $\phi(\mathbf{x})^T \phi(\mathbf{x}_n)$ である。ここで、この内積を表す関数を以下の(4.18)式で表すことを考える。

$$K(\mathbf{x}, \mathbf{x}_n) = \phi(\mathbf{x})^T \phi(\mathbf{x}_n) \quad (4.18)$$

(4.18)式の関数 $K(\mathbf{x}, \mathbf{x}_n)$ をカーネル関数という。このカーネル関数を適切に選定すれば、非線形なデータを線形な高次元のデータに変換して内積するのと同じ効果が得られることが知られている^(95, 97)。

本研究では、以下の(4.19)式で定義される動径基底関数カーネルを使用した⁽⁹⁵⁾。

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (4.19)$$

(4.19)式中の指数関数をテイラー展開すると、多項式の無限和で表される⁽⁹⁶⁾ため、データ $(\mathbf{x}, y)$ を無限次元空間へ引き延ばした写像に対応する。

4.2.2 混合ガウス分布による異常検知

混合ガウス分布 (Gaussian Mixture Model: GMM) とは、複数の正規分布を用いて未知の確率分布を表現する手法である。確率分布はデータ密度に基づいて推定

される。第3章の3.3.1項や3.3.2項に示したように、落雷直後に発生した外れ値はデータ密度の低い領域に現れることが明らかとなっているため、外れ値検知に有効なGMMは本研究の異常検知モデルとして適切であると考えられる。

(4.20)式から(4.23)式にGMMの基本式を示す。なお、 π_k は正規分布 k の持つ重み係数、 μ_k と Σ_k は正規分布 k の平均値と一般共分散行列である。 Θ はこれら3つのパラメータ π_k , μ_k , Σ_k の正規分布毎の集合を示す。また、 K は正規分布の総数を示す混合分布数であり、GMMのハイパーパラメータである。

$$p(\mathbf{x}|\Theta) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}|\mu_k, \Sigma_k) \quad (4.20)$$

$$\mathcal{N}(\mathbf{x}|\mu_k, \Sigma_k) = \frac{\exp\left(-\frac{1}{2}(\mathbf{x}-\mu_k)^T \Sigma_k^{-1}(\mathbf{x}-\mu_k)\right)}{(2\pi|\Sigma_k|)^{\frac{d}{2}}} \quad (4.21)$$

$$0 \leq \pi_k \leq 1 \quad (4.22)$$

$$\sum_{k=1}^K \pi_k = 1 \quad (4.23)$$

(4.20)式と(4.21)式に示すように、GMMは複数の重み付き正規分布の和で表される。GMMを用いれば、 d 次元のデータ $\mathbf{x}$ が従う確率分布をモデル化することができる。(4.22)式と(4.23)式に示すように、重み係数 π は合計が1になるように制限されているため、(4.20)式の $p(\mathbf{x}|\Theta)$ を $\mathbf{x}$ の全区間上で積分すると、その値は1になる。したがって、 $p(\mathbf{x}|\Theta)$ を確率密度関数として扱うことができる。

以下の図4.4に示したGMMの適用例では、1次元特徴量の確率分布を3つの正規分布で近似している。ただし、図4.4のデータが3つの正規分布に従うことは既知としている。このように、データの出現頻度分布が複数の正規分布の重ね合わせで表現できることが予め分かっている場合には、GMMを用いることでデータ分布を正確に近似できる。しかし、実際に扱う問題がこのように理想的な条件を持っていることは稀である。したがって、現実的にはデータの出現頻度分布が未知であっても、出現頻度分布を近似する方法としてGMMが用いられることが多い。





図4.4 GMM を用いた異常検知の実行例

次に，多変量特徴量の確率分布を GMM で近似した例を図 4.5 に示す。(a)に示した多変量特徴量を 5 つの多変量正規分布によって近似したのが(b)である。(c)は 5 つの多変量正規分布を合成し，一つの確率分布としている。このように，出現頻度分布が未知のデータに対しても，適切な混合分布数 K を設定すれば，精度良くデータ分布を近似することができる。


GMM のパラメータ Θ を最適化するためには，以下の(4.24)式で定義される対数尤度を最大化させる必要がある。尤度とは，データ分布に対する確率分布の尤もらしさを示す値であり，確率分布がデータ分布に一致するほど高い値になる。

$$L(\Theta) = \ln \prod_{i=0}^N p(x_i | \Theta) \quad (4.24)$$


(4.24)式の対数尤度を最大化するには，EM アルゴリズム (Expectation-Maximization Algorithm) ⁽⁹⁸⁾ が用いられる。EM アルゴリズムには以下の(4.25)式で定義される負担率 γ と，(4.26)式から(4.28)式に示される各パラメータの更新式が用いられる。まず， π_k ， μ_k ， Σ_k に初期値を与え，(4.25)式で負担率 γ を計算する。次に(4.26)式から(4.28)式を用いて π_k ， μ_k ， Σ_k を更新する。ただし，(4.28)式中の μ_k は更新後のものであることに注意する。この負担率の計算とパラメータの更新を，パラメータが収束するまで繰り返すことで，対数尤度を最大化することができる。



(a) 多変量特徴量



(b) 多変量正規分布による近似



(c) 多変量正規分布の合成

図4.5 多変量 GMM による多変量特徴量のモデル化

$$\gamma_{nk} = \frac{\pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)} \quad (4.25)$$

$$\pi_k = \frac{\sum_{n=1}^N \gamma_{nk}}{N} \quad (4.26)$$

$$\boldsymbol{\mu}_k = \frac{\sum_{n=1}^N \gamma_{nk} \mathbf{x}_n}{\sum_{n=1}^N \gamma_{nk}} \quad (4.27)$$

$$\boldsymbol{\Sigma}_k = \frac{\sum_{n=1}^N \gamma_{nk} (\mathbf{x}_n - \boldsymbol{\mu}_k)(\mathbf{x}_n - \boldsymbol{\mu}_k)^T}{\sum_{n=1}^N \gamma_{nk}} \quad (4.28)$$

なお、EM アルゴリズムを実行するためには、混合分布数 K を予め決定しておく必要がある。 K の選定方法にはベイズ情報量規準 (Bayesian Information Criterion: BIC) ⁽⁹⁹⁾ を用いることが多い。BIC はクラスター分析手法に適切なモデルを選択するために考案された評価基準であり、複数のクラスに分かれているデータに対して有効である。しかし、GMM を異常検知手法として用いる場合、BIC が高くても異常検知精度が高くなるとは限らない^(43, 98)。そこで本研究では、いくつかの K を設定して異常検知を行い、最も異常検知精度が高かった $K=128$ を採用した。なお、 K の選定に用いた結果は付録 A に示す。

GMM を用いて異常検知を行うには、確率密度に基づいて異常度を定義する必要がある。通常、異常度は以下の(4.29)式に示す負の対数尤度で定義される。

$$\text{score} = -\ln p(\mathbf{x}^{(n)} | \boldsymbol{\Theta}) \quad (4.29)$$

正常データのみを GMM でモデル化すれば、データの予測分布 $p(\mathbf{x} | \boldsymbol{\Theta})$ が得られる。この予測分布を用いれば、あるデータ $\mathbf{x}^{(n)}$ の確率密度 $p(\mathbf{x}^{(n)} | \boldsymbol{\Theta})$ を求めることができる。異常データは発生する確率が低いため、 $\mathbf{x}^{(n)}$ が異常データであれば、 $p(\mathbf{x}^{(n)} | \boldsymbol{\Theta})$ は小さくなる。したがって、(4.29)式より、 $\mathbf{x}^{(n)}$ が発生する確率の低い異常なデータであれば異常度は大きくなる。この異常度に閾値を設ければ、正常値と異常値の判別が可能になる。

4.2.3 オートエンコーダによる異常検知




図4.6 オートエンコーダ

オートエンコーダ（AutoEncoder: AE）は、ニューラルネットワークを用いて構築された自己符号化ネットワークであり、入力層、隠れ層、出力層で構成される。通常、隠れ層のノード数は入力層のノード数より小さく、次元を圧縮する役割を持つ。一方、出力層のノード数は入力層のノード数と等しくなっており、次元圧縮された入力値を復元する役割を持つ。このように、入力された値を次元圧縮・復元しているため、入力層-隠れ層をエンコーダ、隠れ層-出力層をデコーダと呼ぶ。図 4.6 に AE のネットワークの例を示す。

1 層目の隠れ層 z_1 の値は、入力層の値と重み $w^{0,1}$ 、活性化関数 f を用いて以下の (4.30) 式で計算できる。なお、活性化関数は非線形の特性を近似するための非線形関数であり、Sigmoid 関数や ReLU 関数がよく用いられる。(4.30) 式が計算できれば、2 層目以降のノードも同様に計算できる。このように、入力層の値から出力層の値までを計算する過程を順伝播という。

$$z_{1,j} = f\left(\sum_{i=0}^{H_1} w_{i,j}^{0,1} x_i\right) \quad (4.30)$$

AE を用いて異常検知を行うには、まず、正常データのみを AE に入力し、入力と出力の差（再構成誤差）が最小になるよう、重みを最適化する必要がある。重みが最適化されれば、AE は正常データを精度良く再現することが可能となる。し

かし，この AE は正常データに対してのみ最適化されているため，異常データが
入力されると，入力を精度良く再現できない。このときの再構成誤差を異常度と
して定義し閾値を設ければ，異常検知が可能である。本研究では，再構成誤差と
して(4.31)に示す二乗誤差を用いた。

$$E(x, \hat{x}) = \frac{1}{2}(x - \hat{x})^2 \quad (4.31)$$

次に，勾配降下法を用いた重みの最適化について説明する。再構成誤差 E が与
えられた時，この値が最小となるような重みを見つけるには，(4.32)式の更新式を
用いる。この更新式を何度も計算することで，重み w は最適値へ収束する。

$$w_{i,j}^{k-1, k^{new}} = w_{i,j}^{k-1, k} - \eta \frac{\partial E}{\partial w_{i,j}^{k-1, k}} \quad (4.32)$$

(4.32)式からも明らかなように，重みの更新には w に対する E の勾配を用いてい
る。なお， η は学習率と呼ばれ，更新量が大きくなりすぎないように小さな値を設定
しておくことで，学習を安定させることができる。また， $w_{i,j}^{k-1, k}$ は $k-1$ 層の i 番
目のノードと， k 層の j 番目のノードを結ぶ重みを表している。ここで，(4.32)式
の右辺第 2 項は，連鎖率を用いて以下の(4.33)式に分解できる。

$$\frac{\partial E}{\partial w_{i,j}^{k-1, k}} = \frac{\partial E}{\partial I_i^k} \frac{\partial I_i^k}{\partial w_{i,j}^{k-1, k}} \quad (4.33)$$

なお， I_i^k は k 層 i 番目ノードへの入力値である。ここで，(4.33)式の右辺第 1 項を
変数 δ と置く。

$$\delta_i^k = - \frac{\partial E}{\partial I_i^k} \quad (4.34)$$

また，右辺第 2 項より，以下の(4.35)式が導出できる。

$$\frac{\partial I_i^k}{\partial w_{i,j}^{k-1, k}} = \frac{\partial \sum_{l=0}^{n_{k-1}} w_{i,l}^{k-1, k} O_l^{k-1}}{\partial w_{i,j}^{k-1, k}} = O_j^{k-1} \quad (4.35)$$

なお， O_j^{k-1} は $k-1$ 層 j 番目ノードの出力値である。また， n_{k-1} は $k-1$ 層が持つノ
ード数を意味する。(4.33)式，(4.34)式，(4.35)式を用いれば，(4.32)式は以下の(4.36)
式に書き換えられる。

$$w_{i,j}^{k-1, \text{ new}} = w_{i,j}^{k-1, k} - \eta \delta_i^k O_j^{k-1} \quad (4.36)$$

(4.36)式の計算には δ_i^k が必要である。そこで、連鎖率を用いて δ_i^k を分解すると、(4.37)式が得られる。

$$\delta_i^k = -\frac{\partial E}{\partial I_i^k} = -\frac{\partial E}{\partial O_i^k} \frac{\partial O_i^k}{\partial I_i^k} \quad (4.37)$$

ここで、(4.37)式の右辺第2項は、 k 層 i 番目のノードの入出力の偏微分になっていることが分かる。したがってこれは、単に活性化関数 f の導関数 f' ということになり、以下の(4.38)式が成り立つ。

$$\frac{\partial O_i^k}{\partial I_i^k} = \frac{\partial f(I_i^k)}{\partial I_i^k} = f'(I_i^k) \quad (4.38)$$

(4.37)式の右辺第1項は、 $k=K$ （最終層）かそれ以外かによって導出が異なる。 $k=K$ の場合、再構成誤差 E は最終層の出力 O_i^K で計算されることから、単に E の導関数 E' で表すことができ、(4.39)式が成り立つ。

$$\frac{\partial E}{\partial O_i^K} = \frac{\partial E(O_i^K)}{\partial O_i^K} = E'(O_i^K) \quad (4.39)$$

$0 \leq k < K$ の場合、連鎖率を使って以下の(4.40)式のように変形できる。

$$\begin{aligned} \frac{\partial E}{\partial O_i^k} &= \sum_{l=0}^{n_{k+1}} \left(\frac{\partial E}{\partial I_l^{k+1}} \frac{\partial I_l^{k+1}}{\partial O_i^k} \right) \\ &= \sum_{l=0}^{n_{k+1}} \left(\frac{\partial E}{\partial I_l^{k+1}} \frac{\partial \left\{ \sum_{m=0}^{n_{k+1}} w_{l,m}^{k, k+1} O_m^k \right\}}{\partial O_i^k} \right) \\ &= \sum_{l=0}^{n_{k+1}} \left(\frac{\partial E}{\partial I_l^{k+1}} w_{l,i}^{k, k+1} \right) \end{aligned} \quad (4.40)$$

ここで、(4.34)式を(4.40)式に代入すると、以下の(4.41)式が得られる。

$$\frac{\partial E}{\partial O_i^k} = - \sum_{l=0}^{n_{k+1}} \left(\delta_l^{k+1} w_{l,i}^{k, k+1} \right) \quad (4.41)$$

したがって、(4.32)式に示した重みの更新式は、以下の(4.42)式にまとめることができる。

$$\begin{cases} w_{i,j}^{k-1, k^{new}} = w_{i,j}^{k-1, k} + \eta \delta_i^k O_j^{k-1} \\ \delta_i^k = -f'(I_i^k) E'(O_i^k) & (k=K) \\ \delta_i^k = f'(I_i^k) \sum_{l=0}^{n_{k+1}} \left(\delta_i^{k+1} w_{l,i}^{k, k+1} \right) & (0 \leq k < K) \end{cases} \quad (4.42)$$

ここで注目したいのは、最終層以外では δ の計算に一つ後ろの層の δ が必要であるという点である。最終層の δ は活性化関数の導関数と誤差関数の導関数の積で計算できるため、 δ は後ろの層から順番に計算していくことになる。つまり、重みの更新も後ろの層から順々に行われる。このように、誤差が後ろから伝播して重みを更新していく様子から、この重み更新方法は誤差逆伝播法と呼ばれる。

AEは構造設計が柔軟であり、多層化や畳み込み層の実装、応用モデル（VAE, LSTM-AE等）の活用が可能であるという利点を持つ。また、汎化性能を向上させる転移学習を行うことができるという利点もある。

4.3 特徴量の抽出方法

第3章の結果に基づき、異常検知モデルの特徴量をSCADAデータ項目から抽出する。本研究では、基本的特徴量、入出力的特徴量、正規化パワーカーブ、時間的特徴量の4種類の特徴量を用いた。本節では、それぞれの特徴量の算出方法について説明する。また、その他の事前処理の方法についても説明する。

4.3.1 基本的特徴量

本研究では風速、回転速度、発電出力を基本的特徴量として定義した。第3章の分析結果によると、雷被害を受けた風車の風速-回転速度特性と風速-発電出力特性に外れ値が現れることが明らかとなっている。4.2節で説明した異常検知手法を用いて外れ値を検出できれば、雷被害を正確に検知できると考えられる。

4.3.2 入出力的特徴量

本研究では回転速度の予測誤差と、発電出力の予測誤差を入出力的特徴量として定義した。本項では、それぞれの特徴量の抽出方法について説明する。なお、予測誤差の算出方法は、基本的に「4.2.1 回帰モデルによる異常検知」で説明し

た内容に基づいている。

入出力的特徴量を用いることで、運転モードに対して頑健な異常検知が期待できる。風車が定格運転と出力抑制運転という 2 つの運転モードを持つことは第 2 章 2.1 節で説明した。この出力抑制運転は稀にしか行われないため、基本的特徴量のみに基づいたデータドリブン型の異常検知では、出力抑制運転時のデータを異常と誤認識する可能性がある。そこで、出力抑制運転に関するドメイン知識を踏まえた予測モデルを構築する。これにより、予測誤差は運転モードに依存しにくい特徴量となることが期待できる。

(1) 回転速度の予測誤差

予め構築した回転速度予測モデルの予測誤差を特徴量とした。まず、回転速度予測モデルの構築方法について説明する。本予測モデルは以下の図 4.7 に示したフローチャートに基づいて回転速度を予測する。最初に、風速、回転速度、回転速度設定値を正常運転時の SCADA データから取得する。回転速度設定値とは、過回転防止のために設定された回転速度の上限値であり、風車はこの値を超えないようピッチ制御される。次に、0 rpm を除外した回転速度を風速の一次関数と見做し、線形回帰を行う。最後に、回帰式が予測した回転速度予測値と回転速度設定値を比較し、値が低い方を回転速度予測値として採用する。

この予測モデルによって求めた回転速度予測値と、実際の回転速度の差を特徴量とした。予測モデルは正常データのみを学習しているため、異常な値が入力されると予測精度が落ち、誤差が大きくなると考えられる。したがって、予測誤差の大きさを見ることで、異常値の識別が期待できる。




図4.7 回転速度予測モデルの構築方法

(2) 発電出力の予測誤差

予め構築した発電出力予測モデルの予測誤差を特徴量とした。まず、発電出力予測モデルの構築方法について説明する。本予測モデルは、発電出力を予測するパラメータとして風速、回転速度、風向-ナセル偏差、ピッチ角を採用し、これらの値を用いて回帰式を構築した。回帰モデルには、非線形回帰が可能な SVR⁽⁹⁷⁾を採用した。

この予測モデルによって求めた発電出力予測値と、実際の発電出力の差を特徴量とした。予測モデルは正常データのみを学習しているため、異常な値が入力さ

れると予測精度が落ち、誤差が大きくなると考えられる。したがって、予測誤差の大きさを見ることで、異常値の識別が期待できる。

4.3.3 正規化パワーカーブ

本研究では、定格運転時と出力抑制運転時で値が一致するよう正規化したパワーカーブを正規化パワーカーブと定義した。なお、風車のパワーカーブが以下の(4.43)式に従うことを想定している⁽⁴⁹⁻⁵¹⁾。

$$\begin{cases} P = \begin{cases} K_w v_w^3 & (K v_w^3 < P_{max}) \\ P_{max} & (K v_w^3 \geq P_{max}) \end{cases} \\ K_w = \frac{1}{2} C_p \rho A \end{cases} \quad (4.43)$$

ここで、 P は出力、 v_w は風速、 P_{max} は設定された出力の最大値を表す。また、 C_p はブレードの形状等によって決まるパワー係数、 ρ は空気密度、 A は風車のロータ面積である。ここでは K_w を定数と仮定した。

P_{max} は風車の運転モードによって変化し、0 kW から定格出力までの範囲で変更される可能性がある。ここで、 P を P_{max} で、 v_w を $\sqrt[3]{P_{max}}$ でそれぞれ割れば、パワーカーブ (v_w - P 特性) を P_{max} の値に依存しないよう正規化できる。ただし、 P_{max} は出力の上限値として設定される場合と、回転速度の上限値として設定される場合がある。したがって、正規化パワーカーブは図 4.8 に示すフローチャートを用いて計算できる。なお、図 4.8 の $f_{N \rightarrow P}$ は、回転速度の上限値が与えられた時に、出力の上限値を返す関数であり、SCADA データから予め近似しておく必要がある。本研究では、正常運転時の SCADA データを用いて、 $f_{N \rightarrow P}$ を線形回帰で近似した。

パワーカーブと正規化パワーカーブの例を図 4.9 に示す。図 4.9 (a) のパワーカーブの場合、出力は定格 2000 kW で飽和している他、出力抑制運転により 1000 kW で飽和している様子が見られる。一方、図 4.9 (b) の正規化パワーカーブの場合、これらの飽和値が 1 になるよう正規化されており、運転モードに依らず均一な分布を示している。

入出力的特徴量と同様に、正規化パワーカーブを特徴量として用いることで、運転モードに対して頑健な異常検知が期待できる。





図4.8 正規化パワーカーブの計算方法



(a) パワーカーブ

(b) 正規化パワーカーブ

図4.9 正規化パワーカーブの計算例

4.3.4 時間的特徴量

本研究では時間的特徴量を抽出する方法として、スライド窓、移動平均、デルタパラメータを用いた。第 3 章の分析結果によると、雷被害を受けた風車の SCADA データには、外れ値が高頻度かつ集中して現れることが分かっている。したがって、単に外れ値を検出するのでなく、時間的特徴量を用いることで時間変化を考慮した外れ値検出を行う必要があると考えられる。本研究では、基本的特徴量、入出力的特徴量、正規化パワーカーブに対して、スライド窓、移動平均、デルタパラメータをそれぞれ適用することで、時間変化を考慮した特徴量の抽出を試みた。

(1) スライド窓

スライド窓は、時系列データから一定の区間を順にずらしながら、データを抽出する方法である⁽⁹⁴⁾。各時刻の観測点をスカラー値として扱うのではなく、 M_{SW} 個の隣接した観測点をまとめて M_{SW} 次元ベクトルとして扱うことで、一つのデータ点に隣り合った時系列の情報を含めることができる。 $M_{SW}=3$ のスライド窓を 2 次元時系列データに適用した例を図 4.10 に示す。図 4.10 から明らかなように、2 次元の時系列データが 6 次元のベクトルに拡張されている。




図4.10 スライド窓の適用

(2) 移動平均

移動平均とは、スライド窓によって取得したベクトルの平均値を指す。平均の算出方法にはいくつかの種類があるが、本研究では以下の4種類をそれぞれ特徴量として用いた。

- 単純移動平均 (Simple Moving Average : SMA)
- 加重移動平均 (Weighted Moving Average : WMA)
- 指数加重移動平均 (Exponential Moving Average : EMA)
- 正弦加重移動平均 (Sine Weighted Moving Average : SWMA)

(4.44)式から(4.47)式にそれぞれの移動平均を示す。

$$SMA_d^{(n)} = \frac{1}{M_{MA}} \sum_{i=n-M_{MA}+1}^n x_d^{(i)} \quad (4.44)$$

$$WLMA_d^{(n)} = \frac{2}{M_{MA}(M_{MA}+1)} \sum_{i=n-M_{MA}+1}^n i x_d^{(i)} \quad (4.45)$$

$$EMA_d^{(n)} = EMA_d^{(n-1)} + \alpha(x_d^{(n)} - EMA_d^{(n-1)}) \quad (4.46)$$

$$SWMA_d^{(n)} = \sum_{i=n-M_{MA}+1}^n x_d^{(i)} \sin\left(\frac{i}{M_{MA}+1}\pi\right) \quad (4.47)$$

なお、本研究では $M_{MA}=5$ 、 $\alpha=0.1$ とした。

(3) デルタパラメータ

デルタパラメータとは、ある時刻のデータと1つ前のデータの差分を意味する。 n 番目のあるデータ $\mathbf{x}^{(n)}$ のデルタパラメータ $\mathbf{x}_{delta}^{(n)}$ は、以下の(4.48)式を用いて計算できる。(4.48)式からも明らかなように、デルタパラメータは数値微分の後進差分近似と似た形をしており、本質的には微分値と同じ意味を持つ。

$$\mathbf{x}_{delta}^{(n)} = \mathbf{x}^{(n)} - \mathbf{x}^{(n-1)} \quad (4.48)$$

4.3.5 その他の事前処理

本研究では、入力データの事前処理として(4.49)式を用いて特徴量を0-1正規化した。0-1正規化を適用することにより、単位の異なる各特徴量を無次元に揃えることができ、モデルパラメータの最適化が容易になる。ただし、正規化パワーカーブの場合は既に正規化されているため、0-1正規化は適用していない。

$$x_d^{(n)'} = \frac{x_d^{(n)} - \min x_d}{\max x_d - \min x_d} \quad (4.49)$$

ここで $x_d^{(n)}$ は n 番目、 d 次元目のデータを意味する。

また、本研究では運転中の風車の異常検知を前提としているため、停止中の風車のデータは欠測値として除外した。回転速度を特徴量として用いる場合には、回転速度が 0.1 rpm 以下のデータを停止中と見做した。また、発電出力を特徴量として用いる場合には、発電出力が 1 kW 以下のデータを停止中と見做した。

4.4 異常検知精度の評価方法

本研究では異常検知の精度を評価する指標として、混同行列、Recall, Precision を用いた。また、特定の閾値に依存しない評価方法として、受信者操作特性 (Receiver Operating Characteristic : ROC) 曲線とその曲線下部面積 (Area Under the Curve: AUC) , Precision Recall (PR) 曲線と Average Precision (AP) を用いた。本節では、それぞれの評価方法について説明する。

4.4.1 混同行列

混同行列は、以下の図 4.11 に示すように、異常検知の結果を 4 つの事象に分類・整理したものである。それぞれの事象を真陽性 (True Positive: TP) , 真陰性 (True Negative: TN) , 偽陽性 (False Positive: FP) , 偽陰性 (False Negative: FN) と呼ぶ。通常、異常検知に用いるデータは、異常データの割合が正常データと比べて極端に少ないため、単純な正解率を算出するだけでは精度を十分に評価できない。混同行列を用いれば、正常データと異常データを分けて表すことができるため、データの偏りを考慮した検討ができる。

		Predicted	
		Abnormal	Normal
Actual	Abnormal	True Positive (TP)	False Negative (FN)
	Normal	False Negative (FP)	True Negative (TN)

図4.11 混同行列

4.4.2 ROC 曲線

ROC 曲線は、閾値を変化させた時の偽陽性率-真陽性率特性の軌跡を表している⁽¹⁰⁰⁾。真陽性率と偽陽性率は以下の(4.50)式と(4.51)式で計算できる。ROC 曲線の定義から明らかなように、偽陽性率=0の直線、真陽性率=1の直線とROC曲線に囲まれた面積は、異常検知精度が高いほど大きくなる。この面積はAUCと呼ばれ、モデルの性能を評価する基準となる。なお、AUCの値域は0.5から1である。

$$\text{True positive rate} = \frac{TP}{TP+FN} \quad (4.50)$$

$$\text{False positive rate} = \frac{FP}{FP+TN} \quad (4.51)$$

以下の図4.12は、ある異常度に対して閾値を変化させた時のROC曲線を示している。閾値が異常度の最大値よりも大きければ、異常は検出されず、真陽性率と偽陽性率は0になる。閾値を下げていくと、異常データが検出されるようになるため、真陽性率が上昇していく。さらに閾値を下げると正常領域の異常度も閾値を超えるようになり、偽陽性率が上昇してROC曲線は右側へ移動する。閾値が異常度の最小値まで下がると、全てのデータが異常と判別され、真陽性率と偽陽性率は1となる。




図4.12 ROC 曲線と異常度の対応

図 4.13 (a)のように、異常度が異常領域に関係なくランダムに変動している場合、真陽性率と偽陽性率は同じ速度で上昇するため、ROC 曲線は図 4.13 (b)のようになる。そのため、AUC の下限値は 0.5 に近い値となる。また、AUC が 0.5 を下回った場合、それは「異常」と「正常」の定義が逆であることを示している。




図4.13 ROC 曲線とランダムな異常度

4.4.3 PR 曲線

PR 曲線は、閾値を変化させた時の Precision と Recall の軌跡を表している⁽¹⁰¹⁾。Precision と Recall は以下の(4.52)式と(4.53)式で計算できる。この時、全ての Recall で Precision を平均した値を AP といい、1 に近いほど高い異常検知精度であると言える。

$$Precision = \frac{TP}{TP+FP} \quad (4.52)$$

$$Recall = \frac{TP}{TP+FN} \quad (4.53)$$

以下の図 4.14 は、ある異常度に対して閾値を変化させた時の PR 曲線を示している。閾値が異常度の最大値よりも大きければ、異常は検出されず、Precision と Recall は 0 になる。閾値を下げていくと、異常データが検出されるようになるため、FP が無ければ Precision が 1 になり、FN が減ることで Recall が上昇する。さらに閾値を下げると正常領域の異常度も閾値を超えるようになり、FP が増えて Precision が下がる。閾値が異常度の最小値まで下がると、全てのデータが異常と判別され、Recall は 1 になり、Precision は異常データの占める割合と一致する。




図4.14 PR 曲線と異常度の対応

図 4.15 (a)のように、異常度が異常領域に関係なくランダムに変動している場合、閾値を下げると TP と FP が同じ割合で増える。したがって、Precision は異常データの占める割合付近の値を維持する。




図4.15 PR 曲線とランダムな異常度

第 5 章 風車ブレードの雷被害検出

5.1 提案手法の学習・テストプロセス

本手法で用いた異常検知の学習・テストプロセスを図 5.1 に示す。これらのプロセスは Python3.9 で定義され、オープンソースライブラリである scikit-learn と PyTorch を用いて作成された。




図5.1 異常検知の学習・テストプロセス

学習プロセスは以下の手順で実行される。まず、学習データセットから特徴量を抽出し、事前処理を実施する。特徴量の抽出方法と事前処理については第 4 章 4.3 節で述べた。次に、これらの特徴量を用いて機械学習モデルを学習させる。機械学習モデルには GMM または AE を用いた。最後に、学習済みモデルを用いて学習データセットの異常度を計算し、その値に基づいて閾値を決定した。本研究では、学習データセットの異常度の 99 パーセンタイル値を閾値とした。

テストプロセスは以下の手順で実行される。まず、学習プロセスと同じ手順で特徴量の抽出と事前処理が行われる。次に、これらの特徴量を学習済みモデルに

入力し、異常度を得る。最後に、異常度が閾値を超えたデータを異常として検出する。なお、第4章4.4節で説明した評価方法を用いてテストプロセスの異常検知結果を評価した。

5.2 検証方法と使用データ

本研究では、図5.2に示す風車ブレードの雷被害検出手法の実現に向けた取り組みとして、異常検知手法の検証と評価を行った。図5.2に示したように、雷撃を受けた風車の迅速な非常停止については、LDSを用いた方法により既に実現している。ここでは、実際に雷撃を受けて損傷した風車のSCADAデータを用いて異常検知を行うことにより、本手法の実現可能性について検討した。




図5.2 風車ブレードの雷被害検出手法の概念図

図5.2に示した手法を実現するためには、出力抑制運転時の異常検知と定格運転時の異常検知の両方を精度良く行う必要がある。そこで、雷被害を受けた際に出力抑制運転を行っていた風車Bのデータと、雷被害を受けた際に定格運転を行っていた風車Aのデータを用いて異常検知を行った。なお、風車Aでは、入出力的特徴量と正規化パワーカーブの計算に必要なSCADA項目が記録されていなかったため、基本的特徴量と時間的特徴量による異常検知のみを行った。使用したデータセットの詳細を以下の表5.1にまとめる。

表5.1に示したように、正常運転時のSCADAデータを学習データセットとして用いた。なお、AEの学習時には、学習データセットの10%を検証データセットとして用いた。

また、表 5.1 に示したように、雷被害発生時の SCADA データをテストデータとして用いた。なお、出力抑制運転時の異常検知のテストでは出力抑制運転を異常として誤認識していないか確かめるため、正常な出力抑制運転のデータをテストデータに追加した。

表5.1 使用データセットの詳細

Objective	Usage Data	Data period	
		Training/Valid data set	Test data set
Anomaly detection during de-rated operation	Wind turbine B	The data recorded before accident for 40,384 min (approximately 28 days) (including rated and de-rated operation)	The data recorded before and after accident for 20,520 min (approximately 16 days) (de-rated operation)
			The data recorded before accident for about 1,000 min (rated operation)
			The data recorded before accident for about 1,000 min (de-rated operation)
Anomaly detection during rated operation	Wind turbine A	The data recorded after repair for 34,139 min (approximately 23 days) (including rated and de-rated operation)	The data recorded before and after accident for 171 min (rated operation)

GMM と AE の学習に使用したハイパーパラメータを表 5.2 と表 5.3 にそれぞれ示す。なお AE の学習時には、表 5.3 に示したハイパーパラメータの範囲でベイズ最適化に基づくパラメータ探索⁽¹⁰²⁾を行い、再構成誤差が最小となったハイパーパラメータを採用した。また、学習回数は 100 エポックを上限とし、検証データの再構成誤差が下がらない状態が 10 エポック続いた場合は、学習を早期終了した。

表5.2 GMM のハイパーパラメータ

Hyperparameter	Value/Description
The number of Gaussian distributions	128
The covariance type of Gaussian distributions	Each component has its own general covariance matrix.
The convergence threshold of EM iterations	0.001
The number of EM iterations to perform	100
The number of initializations to perform	1
The initializing method for the weights, the means and the precisions	k-means

表5.3 AE のハイパーパラメータ

Hyperparameter	Search Space/Description
Number of encoder layers	3-32
Units per encoder/decoder layer	2-3
Learning rate	10^{-4} - 10^{-2}
Mini-batch size	16, 32, 64, 128
Upper bound of training epochs (with early stopping)	100
Activation function	ReLU
Iterative method	SGD

5.3 検証結果

5.3.1 出力抑制運転時の異常検知


(1) GMM による異常検知

基本的特徴量，入出力的特徴，正規化パワーカーブのそれぞれを GMM の特徴量として用いた異常検知の結果を示す。図 5.3 に特徴量ごとの ROC 曲線と PR 曲線を示し，AUC と AP の一覧を表 5.4 に示す。


表 5.4 と図 5.3 から明らかなように，風速，回転速度，発電出力の 3 つを特徴量として用いた場合の異常検知精度が最も高かった。

表5.4 基本的特徴量，入出力的特徴，正規化パワーカーブによる異常検知の
AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.880	0.914
wind speed, power	0.888	0.922
wind speed, rotational speed, power	0.940	0.969
rotational speed prediction error, power prediction error	0.910	0.932
scaled power curve	0.747	0.826



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.3 基本的特徴量，入出力的特徴，正規化パワーカーブによる異常検知の
ROC 曲線と PR 曲線

次に，基本的特徴量，入出力的特徴，正規化パワーカーブにスライド窓を適用し，GMM の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.4 に示し，AUC と AP の一覧を表 5.5 に示す。


図 5.4 と図 5.3 を比較すると，正規化パワーカーブ以外の特徴量については異常検知精度が向上していることが分かる。これは，スライド窓によって時間要素の入力が可能になったためであると考えられる。なお，正規化パワーカーブを用いる場合は，スライド窓の適用は適切ではないと考えられる。

表5.5 時間的特徴量（スライド窓）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.919	0.949
wind speed, power	0.923	0.942
wind speed, rotational speed, power	0.925	0.946
rotational speed prediction error	0.619	0.714
power prediction error	0.736	0.712
rotational speed prediction error, power prediction error	0.928	0.941
scaled power curve	0.706	0.796



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.4 時間的特徴量（スライド窓）による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量、入出力的特徴、正規化パワーカーブに移動平均を適用し、GMM の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの


ROC 曲線と PR 曲線を図 5.5 に示し、AUC と AP の一覧を表 5.6 に示す。

表5.6 時間的特徴量（移動平均）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.943	0.966
wind speed, power	0.941	0.964
wind speed, rotational speed, power	0.958	0.978
rotational speed prediction error	0.675	0.733
power prediction error	0.816	0.796
rotational speed prediction error, power prediction error	0.944	0.955
scaled power curve	0.761	0.829



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.5 時間的特徴量（移動平均）による異常検知の ROC 曲線と PR 曲線


図 5.5 と図 5.3 を比較すると、全ての特微量について、移動平均の適用によって異常検知精度が向上していることが分かる。これは、移動平均によって時間要素の入力が可能になったためであると考えられる。

次に、基本的特微量、入出力的特徴、正規化パワーカーブのデルタパラメータを計算し、時間的特微量として用いた場合の異常検知結果を示す。特微量ごとの ROC 曲線と PR 曲線を図 5.6 に示し、AUC と AP の一覧を表 5.7 に示す。


表 5.7 から明らかなように、全ての AUC の値が 0.5 に近く、極端に異常検知精度が低くなっている。したがって、GMM はデルタパラメータをモデル化できていない可能性が高い。

表5.7 時間的特微量（デルタパラメータ）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.612	0.719
wind speed, power	0.605	0.716
wind speed, rotational speed, power	0.608	0.710
rotational speed prediction error, power prediction error	0.427	0.598
scaled power curve	0.618	0.726



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.6 時間的特徴量（デルタパラメータ）による異常検知の
ROC 曲線と PR 曲線


(2) AE による異常検知

基本的特徴量，入出力的特徴，正規化パワーカーブのそれぞれを AE の特徴量として用いた異常検知の結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.7 に示し，AUC と AP の一覧を表 5.8 に示す。


図 5.7 と表 5.8 から明らかなように，異常検知精度が最も高い特徴量は正規化パワーカーブである。また最も精度が低い特徴量は入出力的特徴量である。したがって，入出力的特徴量はデータの入出力特性を正確に近似できていない可能性が高い。入出力的特徴量を異常検知に用いるには，入出力特性の精度良い近似が必要である。

表5.8 基本的特徴量，入出力的特徴，正規化パワーカーブによる異常検知の
AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.775	0.809
wind speed, power	0.730	0.772
wind speed, rotational speed, rotational speed, power	0.721	0.767
rotational speed prediction error, power prediction error	0.497	0.571
scaled power curve	0.789	0.850



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.7 基本的特徴量，入出力的特徴，正規化パワーカーブによる異常検知の
ROC 曲線と PR 曲線

次に，基本的特徴量，入出力的特徴，正規化パワーカーブにスライド窓を適用し，AE の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.8 に示し，AUC と AP の一覧を表 5.9 に示す。


表 5.9 と表 5.8 を比較すると,回転速度の予測誤差と発電出力の予測誤差の 2 つを用いた場合と,風速,回転速度,発電出力の 3 つを用いた場合を除いて,スライド窓の適用により異常検知精度が向上した事が分かる。

表5.9 時間的特徴量（スライド窓）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.784	0.815
wind speed, power	0.745	0.775
wind speed, rotational speed, power	0.719	0.766
rotational speed prediction error	0.313	0.536
power prediction error	0.463	0.559
rotational speed prediction error, power prediction error	0.464	0.559
scaled power curve	0.809	0.864



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.8 時間的特徴量（スライド窓）による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量、入出力的特徴、正規化パワーカーブに移動平均を適用し、AE の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.9 に示し、AUC と AP の一覧を表 5.10 に示す。

表 5.10 から明らかなように、回転速度の予測誤差と発電出力の予測誤差の 2 つを用いた場合を除いて、異常検知精度が向上している。このことから、移動平均により時間的特性が抽出できていると考えられる。

表5.10 時間的特徴量（移動平均）による異常検知の AUC と AP

Features	AUC	AP
wind speed, rotational speed	0.792	0.816
wind speed, power	0.730	0.771
wind speed, rotational speed, power	0.738	0.771
rotational speed prediction error	0.289	0.519
power prediction error	0.495	0.573
rotational speed prediction error, power prediction error	0.495	0.573
scaled power curve	0.813	0.866





図5.9 時間的特徴量（移動平均）による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量，入出力的特徴，正規化パワーカーブのデルタパラメータを計算し，時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.10 に示し，AUC と AP の一覧を表 5.11 に示す。


表 5.11 から明らかなように，全ての AUC の値が 0.5 に近く，極端に異常検知精度が低くなっている。したがって GMM 同様，AE はこれらのデルタパラメータをモデル化できておらず，デルタパラメータは出力抑制運転時の異常検知に必要な特徴量ではない可能性が高い。

表5.11 時間的特徴量（デルタパラメータ）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.633	0.733
wind speed, power	0.668	0.748
wind speed, rotational speed, power	0.651	0.739
rotational speed prediction error, power prediction error	0.385	0.548
scaled power curve	0.600	0.710



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.10 時間的特徴量（デルタパラメータ）による異常検知の ROC 曲線と PR 曲線

5.3.2 定格運転時の異常検知

(1) GMM による異常検知


基本的特徴量を GMM の特徴量として用いた異常検知の結果を示す。特徴量ご

との ROC 曲線と PR 曲線を図 5.11 に示し、AUC と AP の一覧を表 5.12 に示す。


図 5.11 および表 5.12 から明らかなように、風速と回転速度の 2 つを用いた場合を除いて、AUC と PR が低いことが分かる。したがって、発電出力を特徴量として使用する場合、基本的特徴量だけでは定格運転時の異常検知を十分に行えない可能性が高い。

表5.12 基本的特徴量による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.800	0.706
wind speed, power	0.627	0.509
wind speed, rotational speed, power	0.437	0.212



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.11 基本的特徴量による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量にスライド窓を適用し、GMM の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.12 に示し、AUC と AP の一覧を表 5.13 に示す。


図 5.12 から明らかなように、スライド窓を適用することで ROC 曲線と PR 曲線が改善され、異常検知精度が向上している。このことから、定格運転時の異常検知を行うには、特徴量へのスライド窓の適用が有効であると考えられる。

表5.13 時間的特徴量（スライド窓）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.954	0.850
wind speed, power	0.883	0.680
wind speed, rotational speed, power	0.872	0.748



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.12 時間的特徴量（スライド窓）による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量に移動平均を適用し、GMM の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.13 に示し、AUC と AP の一覧を表 5.14 に示す。


図 5.13 から明らかなように、移動平均を適用することで ROC 曲線と PR 曲線が改善され、異常検知精度が向上している。また、表 5.14 から明らかなように、風速、回転速度、発電出力の 3 つを特徴量とした場合の AUC と AP は 1 であり、これは、正常と異常を全て正しく判定できることを示している。

表5.14 時間的特徴量（移動平均）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.997	0.989
wind speed, power	0.983	0.916
wind speed, rotational speed, power	1.000	1.000



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.13 時間的特徴量（移動平均）による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量のデルタパラメータを計算し、時間的特徴量として用いた場合の異常検知結果を示す。それぞれの ROC 曲線と PR 曲線を図 5.14 に示し、AUC と AP の一覧を表 5.15 に示す。


図 5.14 と図 5.11 を比較すると明らかなように、デルタパラメータの適用により、ROC 曲線と PR 曲線が改善していることが分かる。ただし、移動平均やスライド窓と比べると、AUC や AP の値は大きくない。

表5.15 時間的特徴量（デルタパラメータ）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.830	0.647
wind speed, power	0.796	0.486
wind speed, rotational speed, power	0.857	0.590



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.14 時間的特徴量（デルタパラメータ）による異常検知の ROC 曲線と PR 曲線


(2) AE による異常検知

基本的特徴量を用いた場合の異常検知結果を示す。それぞれの ROC 曲線と PR 曲線を図 5.15 に示し，AUC と AP の一覧を表 5.16 に示す。


表 5.16 から明らかなように，AUC と AP は比較的低く，基本的特徴量だけでは定格運転時の異常検知を十分に行えない可能性が高い。

表5.16 基本的特徴量による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.790	0.699
wind speed, power	0.762	0.584
wind speed, rotational speed, power	0.815	0.654



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.15 基本的特徴量による異常検知の ROC 曲線と PR 曲線

次に、基本的特徴量にスライド窓を適用し、GMM の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.16 に示し、AUC と AP の一覧を表 5.17 に示す。


図 5.16 と表 5.17 から明らかなように、スライド窓を用いることで異常検知精度が大幅に改善している。特に、風速と回転速度を特徴量とした場合の AUC と AP が高いことが分かる。

表5.17 時間的特徴量（スライド窓）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.992	0.969
wind speed, power	0.986	0.888
wind speed, rotational speed, power	0.999	0.988



(a) ROC 曲線



(b) PR 曲線




(c) 凡例

図5.16 時間的特徴量（スライド窓）による異常検知の ROC 曲線と PR 曲線


次に、基本的特徴量に移動平均を適用し、AE の時間的特徴量として用いた場合の異常検知結果を示す。特徴量ごとの ROC 曲線と PR 曲線を図 5.17 に示し、AUC と AP の一覧を表 5.18 に示す。

表5.18 時間的特徴量（移動平均）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.981	0.930
wind speed, power	0.830	0.556
wind speed, rotational speed, power	0.958	0.767



(a) ROC 曲線



(b) PR 曲線



(c) 凡例


図5.17 時間的特徴量（移動平均）による異常検知の ROC 曲線と PR 曲線

図 5.17 および表 5.18 から明らかなように、移動平均を用いることで異常検知精度が大幅に改善している。ただし、図 5.16 および表 5.17 と比較すると、AUC、PR とともに劣っているため、AE に用いる時間的特徴量は、移動平均よりもスライド窓が有効であると考えられる。


次に、基本的特徴量のデルタパラメータを計算し、時間的特徴量として用いた場合の異常検知結果を示す。それぞれの ROC 曲線と PR 曲線を図 5.18 に示し、AUC と AP の一覧を表 5.19 に示す。

表5.19 時間的特徴量（デルタパラメータ）による異常検知の AUC と AP


Features	AUC	AP
wind speed, rotational speed	0.840	0.660
wind speed, power	0.815	0.340
wind speed, rotational speed, power	0.849	0.532



(a) ROC 曲線



(b) PR 曲線



(c) 凡例

図5.18 時間的特徴量（デルタパラメータ）による異常検知の ROC 曲線と PR 曲線

図 5.18 および表 5.19 から明らかなように、デルタパラメータを適用することで異常検知精度が向上している。したがって、定格運転時の異常検知の場合、デルタパラメータは有効なパラメータであると考えられる。ただし、表 5.17 と表

5.18 より，スライド窓や移動平均に比べると寄与度は低い。

5.4 結果についての考察


5.4.1 出力抑制運転時の異常検知についての考察

表 5.4 から表 5.11 から明らかなように，出力抑制運転時の異常検知の中で AUC および AP が最も高いモデルは，風速，回転速度，発電出力の移動平均を特徴量とした GMM である。本モデルの異常検知結果を以下の図 5.19 に示す。なお，図 5.19 (a), (b) は正解ラベルであり，落雷直前を青，落雷直後を赤で表した。なお，風車 B の場合，最後の点検から雷被害の発覚まで 9 回の落雷が観測されており，どの落雷がブレードを損傷させたか明らかとなっていないため，1 回目の落雷の前を正常，9 回目の落雷の後を異常としてラベルを付けた。その間のデータはラベルを付けず，評価に用いなかった。図 5.19 (c), (d) はモデルによる異常検知結果であり，青はモデルが正常と判断したデータ，赤はモデルが異常と判断したデータである。図 5.19 (f) には異常度の時間変化と閾値を示した。また，この結果を元に作成した混同行列を図 5.19 (e) に示した。


図 5.19 から明らかなように，1 回目の落雷以降に異常度が上昇しており，閾値を超えて異常と判断されている。また，15,000 min 付近で異常度が特に大きく上昇していることも分かる。ただし，このテストデータは正常区間が短く，ラベルの無い区間が長いことに留意する必要がある。ラベルの無い区間の一部は正常データである可能性もあるため，モデルが過学習している可能性は否定できない。

モデルが過学習していないか確認するため，正常区間のテストデータの異常検知結果を図 5.20 に示す。図 5.20 の構成は図 5.19 と同様である。ただし，正常区間のため全て正常データで構成されている。また，図 5.20(e) の混同行列は，図 5.20 の異常検知結果に図 5.19(e) の混同行列を合算したものである。



図 5.20 から明らかなように，正常区間であるにもかかわらず，異常度は閾値を超える状態が続いており，データを異常と誤判定している。このことから，本モデルは過学習を起こしている可能性が高い。図 5.20 で用いたデータは，抑制運転状態に観測されたデータである。したがって，本モデルは抑制運転を学習できていないと考えられる。



(a) 風速-発電出力特性 正解ラベル




(b) 発電出力の時間特性 正解ラベル

(c) 風速-発電出力特性
異常検知結果(d) 発電出力の時間特性
異常検知結果


		Predicted	
		Abnormal	Normal
Actual	Abnormal	3217	143
	Normal	0	291

(e) 混同行列




(f) 異常度の時間変化



図5.19 風速，回転速度，発電出力の移動平均を特徴量とした GMM による異常検知の検証結果



(a) 風速-発電出力特性 正解ラベル




(b) 発電出力の時間特性 正解ラベル

(c) 風速-発電出力特性
異常検知結果(d) 発電出力の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	3217	143
	Normal	502	1453

(e) 混同行列




(f) 異常度の時間変化

図5.20 風速，回転速度，発電出力の移動平均を特徴量とした GMM による異常検知の検証結果（正常区間）


次に、正規化パワーカーブの移動平均を特徴量として用いた AE の異常検知結果を図 5.21 に示す。図 5.21 の構成は図 5.19 と同様である。図 5.21 (d)からも明らかのように、15,000 min 付近で異常度が上昇し、閾値を超えて異常と判断されている。これは、図 5.19 の結果とも一致する。したがって、この時間にブレード損傷が発生した可能性は高い。図 5.19 と異なる点は、15,000 min 付近まではラベルの無い区間で異常度が閾値を超えていないことである。したがって、図 5.19 の結果と比べて過学習の可能性は低い。

本モデルでも同様に、モデルが過学習していないか確認するため、正常区間のテストデータの異常検知結果を図 5.22 に示す。図 5.22 の構成は図 5.20 と同様である。



図 5.22 と図 5.20 を比較すると明らかなように、正常区間で発生する偽陽性が大幅に削減されている。したがって、本モデルは抑制運転状態を学習できている可能性が高い。本モデルは特徴量に正規化パワーカーブを用いているため、運転モードに頑健な異常検知が実現できたと考えられる。ただし、風速の強い領域では異常度が上昇して閾値を超えている点には、対策が必要であると考えられる。



(a) 風速-発電出力特性 正解ラベル




(b) 発電出力の時間特性 正解ラベル

(c) 風速-発電出力特性
異常検知結果(d) 発電出力の時間特性
異常検知結果


		Predicted	
		Abnormal	Normal
Actual	Abnormal	1750	1610
	Normal	0	291

(e) 混同行列




(f) 異常度の時間変化



図5.21 正規化パワーカーブの移動平均を特徴量とした AE による
異常検知の検証結果



(a) 風速-発電出力特性 正解ラベル




(b) 発電出力の時間特性 正解ラベル

(c) 風速-発電出力特性
異常検知結果(d) 発電出力の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	1750	1610
	Normal	52	1159

(e) 混同行列



(f) 異常度の時間変化

図5.22 正規化パワーカーブの移動平均を特徴量とした AE による
異常検知の検証結果（正常区間）


5.4.2 定格運転時の異常検知についての考察

表 5.12 から表 5.19 を見ると明らかなように、最も AUC・AP が高いモデルは、風速、回転速度、発電出力の移動平均を特徴量とした GMM である。図 5.23 にこのモデルの異常検知結果を示す。なお、図 5.23 (a), (b) は正解ラベルであり、落雷直前を青、落雷直後を赤で表した。図 5.23 (c), (d) はモデルによる異常検知結果であり、青はモデルが正常と判断したデータ、赤はモデルが異常と判断したデータである。図 5.23 (f) には異常度の時間変化と閾値を示した。また、この結果を元に作成した混同行列を図 5.23 (e) に示した。


図 5.23 (d), (f) から明らかなように、落雷直後に異常度が上昇して閾値を超えている。しかし、落雷前のデータの多くも閾値を超えており、異常として誤認識しているため、モデルが過学習している可能性が高い。閾値を 99% より高くすれば、正常と異常を完全に分離することは可能だが、閾値を学習データのみから算出できなくなるため、現実的ではない。また、落雷後すぐに出力が落ちたことで、一部のデータが異常検知不可になっている点も注意が必要である。以上の理由より、本モデルは AUC・AP が高いものの、実用上問題があることが分かる。

次に、2 番目に AUC・AP が高かった風速、回転速度の移動平均を特徴量とした GMM の異常検知結果を図 5.24 に示す。なお、図 5.24 の構成は図 5.23 と同様である。図 5.24 から明らかなように、落雷後 1 分以内に異常度が上昇して閾値を超えており、データを異常として検知している。図 5.24 (e) から明らかなように、8 件の FP は発生しているものの、FN は 1 件であり、精度の良い雷被害検出が実現できている。



定格運転時の異常検知精度は、抑制運転時と比較して高いため、雷被害検出の実現可能性は十分高いと言える。これは、定格運転時の正常データが十分にあり、モデルの学習が容易であったためであると考えられる。



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果


		Predicted	
		Abnormal	Normal
Actual	Abnormal	12	0
	Normal	68	67

(e) 混同行列




(f) 異常度の時間変化



図5.23 風速，回転速度，発電出力の移動平均を特徴量とした GMM による異常検知の検証結果



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	22	1
	Normal	8	127

(e) 混同行列



(f) 異常度の時間変化

図5.24 風速、回転速度の移動平均を特徴量とした GMM による
異常検知の検証結果

5.4.3 停止時間短縮効果についての考察

本項では、本手法を実際の風車運用に使用した場合に、停止時間をどの程度短縮できるか考察する。考察には風車 A の落雷データを用いる。風車 A には、事故発生後に LDS が導入されており、年間の落雷数を把握することが可能である。この落雷数を基に、LDS の動作により風車を停止した時間と、本手法を用いた場合の停止時間の期待値を比較する。

まず、風車 A の落雷非故障停止時間を求める。落雷非故障停止時間とは、LDS の動作により風車を停止したものの、実際には風車は故障していなかった場合に発生する停止時間である。冬季雷地域のウィンドファームを対象に調査した結果⁽¹³⁾によると、落雷 1 回あたりの平均停止時間は 144.28 時間であった。風車 A では、年間平均 29.5 回の落雷が観測されている。落雷が連続的に発生した場合に重複する停止時間に注意して、平均停止時間を算出した結果、年間平均 1730.93 時間（約 144 日）の停止時間が想定されることが明らかとなった。

次に、本手法を用いた場合の落雷非故障停止時間の期待値を求める。本手法では、正常データの異常度の 99 パーセンタイル値を閾値として定義している。したがって、正常な運用を行った場合にも少なくとも 1 %は偽陽性として検出されることが想定される。年間平均 29.5 回の落雷がある風車に本手法を導入した場合、落雷時に偽陽性が発生する確率 p は

$$p = 1 - (1 - 0.01)^{29.5} = 0.257 \quad (5.1)$$

である。したがって、落雷非故障停止時間の期待値は

$$144.28 \times 0.257 = 37.0 \quad (5.2)$$

と求められ、年間 37 時間であることが分かる。

以上の計算より、全ての風車落雷に対して停止・点検を行った場合と比較すると、本手法を導入することで停止時間を最大 1693.93 時間、97.9%削減できる可能性がある。ただし、偽陽性率 1 %は理想的な値であり、上記の試算結果は最大値であることに留意されたい。以上の試算結果より、本手法は落雷非故障停止時間の短縮に資するものであり、本研究の知見を活用することで大幅な稼働率向上が期待できることが分かる。

第 6 章 結論と展望

6.1 結論

本研究では、SCADA データを用いた風車ブレードの雷被害検出手法について検討した。風力発電事業の健全な成長のためには、雷撃を受けた風車の安全な停止と、迅速な再稼働を実現する必要がある。しかしながら、現状行われている風車の点検手法は、即応性と正確性の両面で問題を抱えており、風車の健全性を迅速かつ正確に把握する新たな手法の開発が期待されている。このような課題を背景に、本研究では SCADA データ分析の結果に基づき、風車ブレード雷被害検出手法を提案した。各章のまとめは以下の通りである。

第 2 章では、風力発電の雷被害様相とその対策手法について調査した結果を報告した。風車の雷被害の中でも最も損傷レベルの高い事故がブレードに関するものであり、ブレードの雷害対策は最重要課題であると結論付けた。その上で、各種雷害対策の手法について調査を行い、本研究の位置づけについて分析した。本研究の提案手法は、損傷レベルの高いブレードの雷被害を防ぐ手段として有効であり、また、停止時間の短縮による稼働率の向上にも寄与するものである。

第 3 章では、実際に雷被害を受けた風車の SCADA データを分析し、雷被害の発生と関係の深い SCADA 項目を抽出した。分析の結果、雷被害を受けた風車の風速-回転速度特性、風速-発電出力特性には、高頻度かつ集中した外れ値が現れることが明らかとなった。また、SCADA データからこれらの外れ値を観測するためには、少なくとも 1 分値が必要であることも明らかとなった。

第 4 章では、機械学習を用いた異常検知手法と、特徴量の抽出方法について述べた。本研究では、外れ値検知が可能な異常検知手法として GMM と AE を採用した。また、第 3 章の分析結果で得られた知見に基づき、基本的特徴量、入出力的特徴量、正規化パワーカーブ、時間的特徴量の 4 種の特徴量を定義した。最後に、本研究で使用した異常検知の評価方法について述べた。

第 5 章では、各種特徴量を用いた異常検知手法の結果について、ROC 曲線と PR 曲線を用いて評価・比較を行った。出力抑制運転時の異常検知では、風速、回転速度、発電出力の移動平均を特徴量とした GMM の AUC と AP が最も高い値であ

った。しかし、異常検知の結果を詳しく分析した結果、出力抑制運転の状態を学習できておらず、異常と誤認識している可能性が示唆された。一方、正規化パワーカーブの移動平均を特徴量として用いた AE による異常検知の結果を同様に分析した結果、出力抑制運転状態を異常と誤認識せず、運転モードに対して頑健な異常検知が可能であることが示された。定格運転時の異常検知では、風速、回転速度、発電出力の移動平均を特徴量とした GMM の AUC と AP が最も高い値であった。しかし、異常検知の結果を詳しく分析した結果、正常データの多くが閾値を超えて異常と判断されており、過学習を起こしている可能性が示唆された。一方、風速、回転速度の移動平均を特徴量とした GMM による異常検知の結果を同様に分析した結果、高精度な雷被害検出が可能であることが示された。また、本手法の導入を想定した試算では、落雷非故障停止時間を年間最大 97.9%削減できる可能性があることが示された。これらの結果より、本手法が停止時間の短縮とそれによる稼働率の向上に有効であることが示された。

6.2 将来の展望

本研究では、提案した風車ブレードの雷被害検出手法が、定格運転時の風車と出力抑制運転時の風車のそれぞれに対して適用可能であることを明らかにした。この知見を活用し、落雷検知後に出力抑制運転と異常検知を行い、問題がなければ定格運転に移行しつつ異常検知を継続することで、雷被害拡大のリスクを最小限に抑えつつ、迅速な再稼働を実現できると考えられる。

本研究では実際の風車雷被害事例を用いて異常検知の有効性を示したが、一方で用いた事例は2件のみであり、信頼性や一般性に乏しいという課題もある。本手法の実用化のためには、データの収集と分析を引き続き行い、本手法の信頼性を高める必要がある。また、稼働中の風車に本手法に基づく雷被害検出システムを導入して実証試験を行うことで、落雷を受けた風車を迅速かつ自動的に再稼働できるという前例を作る必要があると考えられる。

上記の課題について解決策を検討・実施しつつ、本研究で得られた知見を活用することで、落雷を受けた風車ブレードの健全性を遠隔から自動監視できる異常検知システムの実現が見込まれる。本手法の導入は、従来の属人的な点検方法を

大きく変えるための重要な一歩であり，安全かつ迅速な風車の再稼働を実現できると考えられる。本手法を用いることで，停止時間の短縮と稼働率の向上に資する効率的な風車運用の実現が期待される。

謝辞

本研究を遂行するにあたり、熱心かつ丁寧なご指導を賜りました中部大学大学院工学研究科電気電子工学専攻の山本和男教授に深く感謝申し上げます。本論文をまとめるにあたり、有益なご助言を賜りました中部大学大学院工学研究科電気電子工学専攻の中村圭二教授，工学研究科情報工学専攻の山下隆義教授，国立研究開発法人産業技術総合研究所の深山覚氏に謹んで御礼申し上げます。本研究にあたり，広くご指導賜りました国立研究開発法人産業技術総合研究所の緒方淳氏ならびに研究員の皆様方，東京大学先端科学技術研究センターの飯田誠特任准教授，古澤陽子特任研究員，早稲田大学理工学術院の小川哲司教授に心よりお礼申し上げます。本論文の執筆に際し多くの示唆をいただきました本学山本研究室の松岡一輝氏に感謝の意を表します。本研究の遂行にあたり，業務との両立に際して多大なるご理解とご支援を賜りました東京電力パワーグリッド株式会社 多摩総支社 武蔵野配電保守グループの皆様方に深甚なる謝意を表します。最後に，本研究にあたり様々なご助言，ご協力を賜りました本学山本研究室の皆様方，本学機械知覚&ロボティクスグループ（MPRG）の皆様方に，厚く御礼申し上げます。

この成果は，NEDO（国立研究開発法人新エネルギー・産業技術総合開発機構）の助成事業（グリーンイノベーション基金事業）（JPNP21015）の結果得られたものです。

参考文献

- (1) United Nations Framework Convention on Climate Change (UNFCCC), Summary of Global Climate Action at COP 28, Accessed: May 09, 2025. URL: https://unfccc.int/sites/default/files/resource/Summary_GCA_COP28.pdf?utm_source=chatgpt.com
- (2) 経済産業省, 第 7 次エネルギー基本計画, Accessed: Nov. 22, 2025. URL: https://www.enecho.meti.go.jp/category/others/basic_plan/pdf/20250218_01.pdf
- (3) REN21, Renewables 2022 Global Status Report, URL: <https://www.ren21.net/gsr-2022/>
- (4) 川口哲郎, 洋上風力発電に上昇気流, 日刊工業新聞, Dec. 24, 2020.
- (5) Y. Goto and K. Narita, Electrical characteristics of winter lightning, *Journal of Atmospheric and Solar-Terrestrial Physics*, vol. 57, pp. 449–458, (1995).
- (6) M.Miki, T. Miki, A. Asakawa, T. Shindo, and S. Yokoyama, Characteristics of upward leaders of winter lightning in the coastal area of the sea of japan, *IEEEJ Trans. Power Energy*, vol. 132, no. 6, pp. 560–567, (2012).
- (7) 電気・電磁機器の雷保護検討委員会, 電気・電子機器の雷保護 —ICT 社会をささえる—, 電気設備学会, オーム社, (2011-8).
- (8) M. Ishii, M. Saito, D. Natsuno, and A. Sugita, Lightning incidence on wind turbines in winter, *2014 International Conference on Lightning Protection (ICLP)*, (2014), DOI: 10.1109/iclp.2014.6973409.
- (9) 高田吉治, 風力発電設備と雷—その影響と対策—, 成山堂書店, (2015).
- (10) Ministry of Economy Trade and Industry, New energy power generation facility accident response and structural strength working group, Accessed: Aug. 26, 2025. URL: https://www.meti.go.jp/shingikai/sankoshin/hoan_shohi/denryoku_anzen/newenergy_hatsuden_wg/index.html
- (11) 経済産業省, 発電用風力設備の技術基準の解釈, Accessed: Nov. 23, 2025. URL: https://www.meti.go.jp/policy/safety_security/industrial_safety/law/20241001_huugikaisiyaku.pdf

- (12) K. Yamamoto, H. Kazui, and S. Izuchi, Influence of lightning strike on availability of wind turbine and its damage analysis, in *2022 36th International Conference on Lightning Protection (ICLP)*, IEEE, Oct. 2022.
DOI: 10.1109/iclp56858.2022.9942613.
- (13) H. Kazui, K. Yamamoto, and S. Sumi, Influence of Lightning Detections and Damages on Availability of Wind Turbine Generation Systems, *J. Inst. Electr. Eng. Jap.*, vol. HV19076, (2019).
- (14) 本庄暢之, 風車の雷害調査結果と雷リスクマネジメントの検討, 風力エネルギー利用シンポジウム, (2018).
- (15) M. Anderson, Supervisory Control and Data Acquisition. Available, Accessed: Apr. 10, 2025. URL: <https://www.realpars.com/blog/scada>
- (16) S. Boyer, SCADA: supervisory control data acquisition, International Society Automation, (2009).
- (17) S. Letzgus, Change-point detection in wind turbine SCADA data for robust condition monitoring with normal behaviour models, *Wind Energy Sci.*, vol. 5, no. 4, pp. 1375–1397, (2020).
- (18) Z. Mehmood and Z. Wang, Enhanced anomaly detection and normal behaviour power curve modelling in wind farm SCADA data: A hybrid approach, *Research Square*, Oct. 21, 2024. DOI: 10.21203/rs.3.rs-5288737/v1.
- (19) X. Liu, S. Lu, Y. Ren, and Z. Wu, Wind turbine anomaly detection based on SCADA data mining, *Electronics (Basel)*, vol. 9, no. 5, p. 751, (2020).
- (20) R. K. Pandit and D. Infield, SCADA Based Wind Turbine Anomaly Detection Using Gaussian Process (GP) Models for Wind Turbine Condition Monitoring Purposes, *IEEE Intl. Conf. on Probab. Methods Appl. to Power Syst. (PMAPS)*, vol. 12, no. 11, pp. 1249–1255, (2018).
- (21) L. Tao, Q. Siqi, Y. Zhang, and H. Shi, Abnormal Detection of Wind Turbine Based on SCADA Data Mining, *Math. Probl. Eng.*, vol. 2019(11):1–10, (2019), DOI: 10.1155/2019/5976843.
- (22) W. Yang, R. Court, and J. Jiang, Wind turbine condition monitoring by the approach

- of SCADA data analysis, *Elsevier Renewable Energy*, vol. 53, pp. 365–376, (2013).
- (23) Y. Cui, P. Bangalore, and L. B. Tjernberg, An Anomaly Detection Approach Based on Machine Learning and SCADA Data for Condition Monitoring of Wind Turbines, *In Proceedings of the IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, pp. 1–6, (2018).
- (24) H. Chen, H. Liu, X. Chu, Q. Liu, and D. Xue, Anomaly detection and critical SCADA parameters identification for wind turbines based on LSTM-AE neural network, *Renew. Energy*, vol. 172, pp. 829–840, (2021).
- (25) A. Yasuda *et al.*, Wind turbine degradation assessment based on condition monitoring model, *Japan Wind Energy Association*, vol. 42, no. 4, pp. 53–62, (2018).
- (26) Y. Wang, X. Ma, and P. Qian, Wind Turbine Fault Detection and Identification Through PCA-Based Optimal Variable Selection, *IEEE Transactions on Sustainable Energy*, vol. 9, no. 4, (2018), DOI: 10.1109/TSTE.2018.2801625.
- (27) A. Stetco *et al.*, Machine learning methods for wind turbine condition monitoring: A review, *ELSEVIER Renewable Energy*, vol. 133, pp. 620–635, (2019).
- (28) 日本風力発電協会, 【速報版】日本の風力発電導入量, Accessed: Nov. 23, 2025. URL: <https://jwpa.jp/information/11062/>
- (29) 日本風力発電協会, 2023 年 12 月末時点日本の風力発電の累積導入量, Accessed: Nov. 23, 2025. URL: <https://jwpa.jp/information/9782/>
- (30) 鈴木孝, 久保典男, (株)日本製鋼所 改良型 2MW 風力発電機 (J82-2.0D) の開発について, *日本風力エネルギー学会誌*, vol. 39, no. 3, pp. 405–406, (2015).
- (31) Vestas, General Specification V90 – 3.0 MW, Accessed: Nov. 23, 2025. URL: https://www.maine.gov/dacf/lupc/projects/windpower/redington/Documents/Section_01_Development_Description/Development_Electric/E_Pro_Reports/Appendix%20A%20V90%20General%20Spec%20950010R1.pdf
- (32) Vestas, MHI Vestas Installs Flagship V174-9.5 MW Prototype, Accessed: Nov. 25, 2025. URL: <https://www.vestas.com/en/media/mwow-press-releases/2020/mhi-vestas-installs-flagship-v174-9-5-mw-prototype>
- (33) D. Wang and N. Takagi, Characteristics of Winter Lightning that Occurred on a

- Windmill and its Lightning Protection Tower in Japan, *IEEJ Trans. Power Energy*, vol. 132, no. 6, pp. 568–572, (2012).
- (34) 宇佐美嘉彬, 五十嵐茉莉, 損害保険会社から見た落雷対策の重要性, 日本風力エネルギー学会誌, vol. 46, no. 3, pp. 426–431.
- (35) 吉田雄太, 本庄暢之, 日本の風力発電所における風車ブレードの雷害被害に関する調査, 電気学会研究会資料, vol. HV-25-102, pp. 45–50, (2025).
- (36) JIS Z 9290-1, 雷保護—第 1 部 : 一般原則.
- (37) 経済産業省, 電気事業法施行規則第 9 4 条の 3 第 1 項第 1 号及び第 2 号に定める定期事業者検査の方法の解釈, Accessed: Jan. 22, 2026. URL: https://www.meti.go.jp/policy/safety_security/industrial_safety/law/files/20210414teiken-kaisyaku.pdf
- (38) 一般社団法人日本風力発電協会, 風力発電設備ブレード点検および補修ガイドライン, Accessed: Oct. 19, 2024. URL: <https://jwpa.jp/information/5716/>
- (39) 経済産業省, デジタル原則を踏まえた当課所管法令の適用に係る解釈の明確化等について, Accessed: Nov. 23, 2025. URL: https://www.meti.go.jp/policy/safety_security/industrial_safety/law/files/digitalgensoku-denryokuanzen.pdf
- (40) Y. Watanabe, Deployment and installed capacity of wind power in Japan, IEA WIND TCP JAPAN, (2022).
- (41) 経済産業省, 買取価格・期間等 (2012 年度～2024 年度) , Accessed: Jan. 22, 2026. URL: https://www.enecho.meti.go.jp/category/saving_and_new/saiene/kaitori/kakaku.html?utm_source=chatgpt.com
- (42) T. Matsui, K. Yamamoto, S. Sumi, and N. Triruttanapiruk, Detection of lightning damage on wind turbine blades using the SCADA system, *IEEE Trans. Power Delivery*, vol. 36, no. 2, pp. 777–784, (2021).
- (43) T. Matsui, K. Yamamoto, and J. Ogata, Study on improvement of lightning damage detection model for wind turbine blade, *Machines*, vol. 10, no. 1, p. 9, (2021).
- (44) T. Matsui, K. Yamamoto, and J. Ogata, Anomaly Detection Using a SCADA Feature Extractor and Machine Learning to Detect Lightning Damage on Wind Turbine

- Blades, *IEEJ Transactions on Electrical and Electronic Engineering*, vol. 17, no. 6, (2022), DOI: 10.1002/tee.23599.
- (45) T. Matsui, K. Yamamoto, and J. Ogata, Anomaly Detection for Wind Turbine Damaged Due to Lightning Strike, *Elsevier EPSR*, vol. 209, (2022), DOI: 10.1016/j.epsr.2022.107918.
- (46) T. Matsui, K. Matsuoka, and K. Yamamoto, Lightning Damage Detection Method Using Autoencoder: A Case Study on Wind Turbines with Different Blade Damage Patterns, *wind*, vol. 5, no. 2, (2025), DOI: 10.3390/wind5020012.
- (47) T. Matsui, K. Matsuoka, and K. Yamamoto, Lightning Damage Detection for Wind Turbine Blade Based on SCADA Data Analysis Using Autoencoder, *XVII SIPDA International Symposium on Lightning Protection*, (2025).
- (48) 伊与田功, 電力発生・輸送工学, オーム社, (2013).
- (49) 牛山泉, 風車工学入門, 森北出版, (2002).
- (50) 牛山泉, 風力エネルギー読本, オーム社, (2005).
- (51) T. Burton, D. Sharpe, N. Jenkins, and E. Bossanyi, *Wind energy handbook*, New York, NY: John Wiley & Sons, (2001).
- (52) 小林文明, 雷, 成山堂書店, (2020).
- (53) T. Takahashi, Riming Electrification as a Charge Generation Mechanism in Thunderstorms, *J. Atmos. Sci.*, vol. 35, pp. 1536–1548, (1978).
- (54) 牛尾知雄, 雷の物理とその観測技術, 日本物理学会, vol. 71, no. 4, pp. 235–238, (2016).
- (55) 日高邦彦, 高電圧工学, 数理工学社, (2009).
- (56) 横山茂, 雷現象と雷サージの伝搬, 電気設備学会誌, vol. 35, no. 2, pp. 83–86, (2015).
- (57) 高田吉治, 雷, 日本風力エネルギー学会誌, vol. 36, no. 3, pp. 446–443, (2012).
- (58) NEDO, 日本型風力発電ガイドライン 落雷対策編, Accessed: Nov. 23, 2025. URL: <https://www.nedo.go.jp/content/100107252.pdf>
- (59) 下川英男, 横山真吾, 高野清貴, 松本隆之, 天野正, 水野克美, 新 JIS に基づく外部雷保護システムの設計・施工実務, 日本電設工業協会, (2004).

- (60) IEC 62305-1, Protection against lightning – Part 1: General principles, (2006).
- (61) 山本和男, 酒井志郎, 柳川俊一, 山田康春, SPD・避雷器と耐雷トランスを用いた雷保護, オーム社, (2015).
- (62) JIS C1400-24:2023, 風力発電システム 雷保護—第 24 部: 雷保護.
- (63) K. Yamamoto and N. Honjo, Latest trends in technologies for sound operation of wind turbines against lightning, *Electr. Eng. Japan*, vol. 205, no. 2, pp. 3–7, (2018).
- (64) IEC 61400-24 Ed. 2.1:2024, Wind energy generation systems - Part 24: Lightning protection, (2006).
- (65) 大林和輝, 深山康弘, 風力発電設備の周辺における電界の観測, 電気学会研究会資料, vol. FTE-16, pp. 1-4, (2016).
- (66) 石井友紀, 鹿島直二, 山本和男, 森川智史, 風車への落雷と雷雲接近様相との関係, 電気学会研究会資料, vol. HV-18-39, pp. 209-212, (2018).
- (67) 石井勝, 齋藤幹久, 夏野大輔, 風力発電用風車ブレードへの冬季の上向き雷着雷状況, *電気学会論文誌 B (電力・エネルギー部門誌)*, vol. 136, no. 2, pp. 220-221, (2016).
- (68) 末永大周 *et al.*, 独立避雷鉄塔による洋上風力発電所の 耐雷設計の提案と基礎実験, 風力エネルギー利用シンポジウム, pp. 35–38, (2016).
- (69) Q. Zhou, C. Liu, X. Bian, K. Lo, and D. Li, Numerical analysis of lightning attachment to wind turbine blade, *Renew. Energy*, vol. 116, pp. 584–593, (2018).
- (70) K. Motoda, K. Yamamoto, T. Matsui, T. Ueno, N. Watanabe, and Y. Moriya, Shape evaluation test of diverter strip for lightning protection of wind turbines, in *2025 13th Asia-Pacific International Conference on Lightning (APL)*, IEEE, June 2025, pp. 295–300.
- (71) Y. Okegawa, S. Zen, N. Takeuchi, Y. Suzuki, and T. Akimoto, Development of paint coatings for lightning protection on wind turbine blades, *J. Occup. Saf. Health*, vol. 17, no. 1, pp. 19–26, (2024).
- (72) 上野敏之, 朝比奈秀一, 仲佐太助, 守谷吉弘, 山本和男, and 尾立志弘, 銅-モリブデン複合材料を用いた風車用ダイバータストリップの試作, 電気学会研究会資料, vol. HV-19-28, pp. 151-155, (2019).

- (73) 上野敏之, 守谷吉弘, 箕田充志, 風力発電用の高耐久レセプタ, 電気学会研究会資料, vol. HV-25-48, pp. 13-16, (2025).
- (74) 風力発電設備の耐雷健全性維持技術と法規制・規格調査専門委員会, 風力発電設備の耐雷健全性維持と稼働率向上のための最新技術の動向, 電気学会, (2020).
- (75) 山本和男, 風車ブレード内ダウンコンダクタの断線検出システム, 電気設備学会誌, vol. 39, no. 7, pp. 452-453, (2019).
- (76) 鹿島直二, 風車ダウンコンダクタ導通確認手法の開発, 中部電力技術開発ニュース, 03/No.168, (2024).
- (77) N. Triruttanapiruk, Disconnection Detection Methods of a Down Conductor in a Wind Turbine Blade, PhD, Chubu University, (2019).
- (78) 八木照文, 本庄暢之, 藤田泰宏, 武藤厚俊, 冬季雷によるあわら北潟風力発電所とひびき風力発電所のレセプタ脱落事故について, 風力エネルギー利用シンポジウム, pp. 261-264, (2014).
- (79) T. Takei and S. Sano, Blade inspection robot for wind turbine generator using ropes, *J. Robot. Soc. Jpn.*, vol. 41, no. 10, pp. 829-832, (2023).
- (80) 飯田誠, 風車ブレード損傷の影響と画像認識による損傷検出, 風力エネルギー学会誌, vol. 44, no. 3, pp. 371-374.
- (81) 西尾宣俊, 吉田雄太, 鈴木淳, 本庄暢之, 飯田誠, ブレード補修による風車発電電力量への影響, 風力エネルギー学会誌, vol. 41, no. 4, p. A_33-A_39, (2017).
- (82) 川上博貴, 鈴木洋介, 状態監視システム (CMS) と落雷検出装置の連携, 風力エネルギー学会誌, vol. 46, no. 3, pp. 413-416, (2022).
- (83) CMS の直近観測値を逐次学習する GMM を用いた風車ブレード落雷時の異常検知, 電気学会研究会資料, vol. HV-25-7, pp. 17-22, (2025).
- (84) 市岡遼真, 松井 拓斗, 山本和男, CMS を用いた落雷後の風車ブレード異常検知〜ブレード先端部損傷例の検証〜, presented at the 電気・電子・情報関係学会東海支部連合大会, Aug. 2024, pp. B3-4.
- (85) 菊地孝, 橋本健, 前田峰志, 風車の O&M に貢献するモニタリングシステム-風車用落雷監視カメラシステム (Lightning Eyes)-, 風力エネルギー学会誌, vol.

- 46, no. 3, pp. 422–425, (2022).
- (86) S. Doi, K. Matsuoka, T. Matsui, and K. Yamamoto, A Study on Detecting of Lightning Strikes on Wind Turbines Using Lightning-eyes and EfficientNet, presented at the The 9th International Symposium on Lightning Protection and High Voltage Engineering (ISLH 2025), Feb. 2025, pp. 69–74.
- (87) C. Asada, K. Yamamoto, and T. Matsui, Study on water droplets detection using AI technology in lightning detection camera system, presented at the The 20th International Symposium on EMC and Transients in Infrastructures /International Student Session (ISET/ISS), Dec. 2024, pp. 20–25.
- (88) T. Murakami, T. Matsui, and K. Yamamoto, Detecting the Location of Lightning strikes on wind turbine blades using the camera system, presented at the The 20th International Symposium on EMC and Transients in Infrastructures /International Student Session (ISET/ISS), Dec. 2024, pp. 16–19.
- (89) 村上剛忠, 松岡一輝, 松井拓斗, and 山本和男, カメラシステムを用いた風車落雷位置検出に関する研究～SCADA との連携～, 風力エネルギー利用シンポジウム, (2025).
- (90) M. Kose, S. Tanaka, K. Yamamoto, S. Sekioka, Y. Baba, and N. Nagaoka, Effective length of counterpoises connected to wind turbine foundation, *IEEE Trans. Power Deliv.*, vol. 36, no. 6, pp. 3956–3963, (2021).
- (91) R. Alipio, M. T. C. Barros, M. A. O. Schroeder, and K. Yamamoto, Analysis of the lightning impulse and low-frequency performance of wind farm grounding systems, *Electric Power Syst. Res.*, vol. 180, no. 106068, p. 106068, (2020).
- (92) C. G. Justus, W. R. Hargraves, A. Mikhail, and D. Graber, Methods for estimating wind speed frequency distributions, *J. Appl. Meteorol.*, vol. 17, no. 3, pp. 350–353, (1978).
- (93) NEDO, 局所風況マップ, Accessed: Nov. 23, 2025. URL: <https://appraw1.info.c.nedo.go.jp/nedo/index.html>
- (94) 井手剛, 入門 機械学習による異常検知 —R による実践ガイド—, コロナ社, (2015).


- (95) 阿部重夫, パターン認識のためのサポートベクトルマシン入門, 森北出版, (2011).
- (96) 奥村吉考, 微分積分学, 培風館, (2016).
- (97) A. J. Smola and B. Schölkopf, A tutorial on support vector regression, *Stat. Comput.*, vol. 14, no. 3, pp. 199–222, (2004).
- (98) C. M. Bishop, Pattern Recognition and Machine Learning, Springer, (2007).
- (99) C. Fraley and A. E. Raftery, How Many Clusters? Which Clustering Method? Answers Via Model-Based Cluster Analysis, *Comput. J.*, vol. 41, no. 8, pp. 578–588, (1998).
- (100) T. Fawcett, An introduction to ROC analysis, *Pattern Recognit. Lett.*, vol. 27, no. 8, pp. 861–874, (2006).
- (101) J. Davis and M. Goadrich, The relationship between Precision-Recall and ROC curves, in *Proceedings of the 23rd international conference on Machine learning - ICML '06*, New York, New York, USA: ACM Press, 2006.
DOI: 10.1145/1143844.1143874.
- (102) J. Wu, X. Chen, H. Zhang, L. Xiong, and H. Lei, Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization, *Journal of Electronic Science and Technology*, vol. 17, no. 1, pp. 26–40, (2019).

付録 A


付録 A では, GMM の混合分布数 K の選定方法に関する検討について報告する。 K を 32, 64, 128, 256 と変化させた場合と, 2 から 256 の間で BIC が最も高い値を採用した場合で異常検知を行い, 異常検知精度を計算した。なお, 検討には風車 A のデータを用い, 特徴量には基本的特徴量の移動平均を用いた。

A.1 混合分布数 K を 32 とした場合

異常検知結果の ROC 曲線と PR 曲線を図 A.1 に示す。また, 異常検知の検証結果を図 A.2 に示す。なお, 図 A.2 (a), (b) は正解ラベルであり, 落雷直前を青, 落雷直後を赤で表した。図 A.2 (c), (d) はモデルによる異常検知結果であり, 青はモデルが正常と判断したデータ, 赤はモデルが異常と判断したデータである。図 A.2 (f) には異常度の時間変化と閾値を示した。また, この結果を元に作成した混同行列を図 A.2 (e) に示した。




(a) ROC 曲線




(b) PR 曲線



図A.1 GMM による異常検知の ROC 曲線と PR 曲線 ($K=32$)



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	19	4
	Normal	0	135

(e) 混同行列




(f) 異常度の時間変化


図A.2 GMM による異常検知の検証結果 ($K=32$)

A.2 混合分布数 K を 64 とした場合

異常検知結果の ROC 曲線と PR 曲線を図 A.3 に示す。また、異常検知の検証結果を図 A.4 に示す。なお、図 A.4 (a), (b) は正解ラベルであり、落雷直前を青、落雷直後を赤で表した。図 A.4 (c), (d) はモデルによる異常検知結果であり、青はモデルが正常と判断したデータ、赤はモデルが異常と判断したデータである。図 A.4 (f) には異常度の時間変化と閾値を示した。また、この結果を元に作成した混同行列を図 A.4 (e) に示した。




(a) ROC 曲線




(b) PR 曲線



図A.3 GMM による異常検知の ROC 曲線と PR 曲線 ($K=64$)



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	18	5
	Normal	0	135

(e) 混同行列




(f) 異常度の時間変化


図A.4 GMM による異常検知の検証結果 ($K=64$)

A.3 混合分布数 K を 128 とした場合

異常検知結果の ROC 曲線と PR 曲線を図 A.5 に示す。また、異常検知の検証結果を図 A.6 に示す。なお、図 A.6 (a), (b) は正解ラベルであり、落雷直前を青、落雷直後を赤で表した。図 A.6 (c), (d) はモデルによる異常検知結果であり、青はモデルが正常と判断したデータ、赤はモデルが異常と判断したデータである。図 A.6 (f) には異常度の時間変化と閾値を示した。また、この結果を元に作成した混同行列を図 A.6 (e) に示した。




(a) ROC 曲線




(b) PR 曲線



図A.5 GMM による異常検知の ROC 曲線と PR 曲線 ($K=128$)



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	23	0
	Normal	8	127

(e) 混同行列




(f) 異常度の時間変化


図A.6 GMM による異常検知の検証結果 ($K=128$)

A.4 混合分布数 K を 256 とした場合

異常検知結果の ROC 曲線と PR 曲線を図 A.7 に示す。また、異常検知の検証結果を図 A.2 に示す。なお、図 A.8 (a), (b) は正解ラベルであり、落雷直前を青、落雷直後を赤で表した。図 A.8 (c), (d) はモデルによる異常検知結果であり、青はモデルが正常と判断したデータ、赤はモデルが異常と判断したデータである。図 A.8 (f) には異常度の時間変化と閾値を示した。また、この結果を元に作成した混同行列を図 A.8 (e) に示した。




(a) ROC 曲線




(b) PR 曲線



図A.7 GMM による異常検知の ROC 曲線と PR 曲線 ($K=256$)



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	23	0
	Normal	30	105

(e) 混同行列




(f) 異常度の時間変化


図A.8 GMM による異常検知の検証結果 ($K=256$)

A.5 BIC に基づいて混合分布数 K を決定した場合


2 から 256 の中で最も BIC の高かった $K=27$ を採用した。異常検知結果の ROC 曲線と PR 曲線を図 A.9 に示す。また、異常検知の検証結果を図 A.10 に示す。なお、図 A.10 (a), (b) は正解ラベルであり、落雷直前を青、落雷直後を赤で表した。図 A.10 (c), (d) はモデルによる異常検知結果であり、青はモデルが正常と判断したデータ、赤はモデルが異常と判断したデータである。図 A.10 (f) には異常度の時間変化と閾値を示した。また、この結果を元に作成した混同行列を図 A.10 (e) に示した。





図A.9 GMM による異常検知の ROC 曲線と PR 曲線 ($K=27$)



(a) 風速-回転速度特性 正解ラベル




(b) 回転速度の時間特性 正解ラベル

(c) 風速-回転速度特性
異常検知結果(d) 回転速度の時間特性
異常検知結果

		Predicted	
		Abnormal	Normal
Actual	Abnormal	18	5
	Normal	0	135

(e) 混同行列



(f) 異常度の時間変化

図A.10 GMM による異常検知の検証結果 ($K=27$)