

論文 / 著書情報
Article / Book Information

題目(和文)	実問題における不確定性を考慮した間接モニタリング技術に関する研究
Title(English)	Research on indirect monitoring technology considering uncertainty in real problems
著者(和文)	米谷直樹
Author(English)	Naoki Yoneya
出典(和文)	学位:博士(工学), 学位授与機関:東京工業大学, 報告番号:甲第12537号, 授与年月日:2023年9月22日, 学位の種別:課程博士, 審査員:天谷 賢治,小酒 英範,田中 正行,佐藤 進,宮崎 祐介
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Tokyo Institute of Technology, Report number:甲第12537号, Conferred date:2023/9/22, Degree Type:Course doctor, Examiner:,,,,
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis

実問題における不確定性を考慮した
間接モニタリング技術に関する研究
Research on indirect monitoring technology
considering uncertainty in real problems

東京工業大学 工学院
システム制御系 システム制御コース
米谷 直樹

This dissertation contains SAE International copyrighted intellectual property, which has been and is licensed with permission for use by Naoki Yoneya, in “Research on indirect monitoring technology considering uncertainty in real problems” only. No further sharing, duplicating, or transmitting is permitted. Originally published in the English Language by SAE International [SAE 2022-32-0031, An estimation method of blended fuel contents by data assimilation for carbon neutral powertrain], by Naoki Yoneya. Copyright © 2022 SAE International. Originally published in the English Language by SAE International [SAE International Journal of Engines 03-17-01-0004, Misfire Detection Technology with Deep Neural Network Based on Ignition Coil Signals], by Naoki Yoneya. Copyright © 2023 SAE International.

目 次

第1章 緒論	4
1.1 背景	4
1.2 社会インフラおよび工業製品の状態モニタリングにおける問題点	5
1.3 本研究のスコープ	6
1.4 適用対象の詳細	8
1.5 研究目的	10
1.6 本論文の構成	11
第2章 従来研究	12
2.1 データ同化	12
2.2 機械学習	25
2.3 海洋鋼構造物の防食状態モニタリング技術	31
2.4 エンジン状態モニタリング技術	33
第3章 ベイズ推定を用いた海洋鋼構造物の犠牲陽極発生電流量同定法の開発	38
3.1 はじめに	38
3.2 逆解析手法	38
3.3 港湾施設における検証実験	44
3.4 データサイエンス技術を活用した今後の展望	50
3.5 まとめ	52
第4章 データ同化を用いた犠牲陽極電流量予測システムの開発	53
4.1 はじめに	53
4.2 解析手法	53
4.3 数値実験による電流予測精度検証	62
4.4 数値実験による犠牲陽極の脱落検知精度検証	68
4.5 実構造物における適用例	72
4.6 まとめ	73
第5章 深層学習を用いた点火コイル信号に基づくエンジン失火検知技術の開発	74
5.1 はじめに	74
5.2 ポスト点火による失火検知コンセプト	75
5.3 エンジン試験およびDNNモデル構築	79
5.4 検証結果および判断根拠の可視化	88
5.5 まとめ	95
第6章 結論	96
6.1 各章のまとめ	96
6.2 今後の課題	97
6.3 本研究で構築した間接モニタリング技術と今後の展望	98
付録1：海洋構造物における犠牲陽極脱落パターン推定手法の提案	100
7.1 本章の目的	100
7.2 解析対象	100
7.3 犠牲陽極脱落による防食限界の推定	102
7.4 データサイエンス活用による今後の展望(犠牲陽極脱落パターンの逆推定)	108

7.5 まとめ	109
付録2：データ同化を用いた自動車エンジンにおける代替燃料混合率推定技術の検討	110
8.1 本章の目的	110
8.2 多種燃料対応エンジンコンセプト	110
8.3 データ同化を用いた燃料混合率推定モデルの構築	113
8.4 数値実験	119
8.5 まとめ	121
研究業績	122
参考文献	123
謝辞	130

第1章 緒論

1.1 背景

近年、地球温暖化に関連した気候変動や自然災害の増加を受け、環境保護を考慮した経済活動を求める動きが活性化している。2009年にスウェーデン出身の環境学者である Rockström らは、人類が地球上で持続的に生存できる限界点を9項目で定量的に示したプラネタリー・バウンダリー(Planetary Boundary)を提唱した¹。項目の1つである気候変動について、大気中の二酸化炭素(Carbon Dioxide, CO₂)濃度の限界値は450ppmと定められているが、2021年時点でのCO₂世界平均濃度は415.7ppmであり、産業革命以前の値である278ppmと比べて大幅な増加を示している²。人間活動をバウンダリーの限界内、すなわち地球環境が持つ容量の範囲内に収めるため、一層の努力が求められている。2015年には国際連合が、2030年までに達成すべき17の目標と169のターゲットで構成される、持続可能な開発目標(Sustainable Development Goals, SDGs)を定義し、国や企業における環境経営の指針を提示した³。項目13「気候変動に具体的な対策を」においては、温室効果ガスを削減し、カーボンニュートラル(Carbon Neutral, CN)を実現するためのターゲットが定義されている。また項目12「つくる責任、つかう責任」においては、持続可能な消費と生産のパターンを確保するためのターゲットが定められている。持続可能な社会の実現に向けた産業界のアクションとして、社会インフラや工業製品におけるライフサイクルを通じたCO₂および環境負荷の低減が求められる。

社会インフラは、道路や橋、空港、港湾、トンネル、ダム等を指し、人々の生活に欠かすことのできない重要な設備であるが、近年それらの老朽化が課題となっている。老朽化の見逃しは人命に関わる重大事故の原因になるだけでなく、不具合発生時の修繕コスト増大や、工事に伴う自然環境への悪影響をもたらす。また、社会インフラ建設におけるCO₂排出量は、建設時の燃料使用による排出(Scope1)、使用した電力の発電時の排出(Scope2)、および材料輸送等のサプライチェーン活動による排出(Scope3)を合計すると、エネルギー消費ベースで1990~2020年度の日本の温室効果ガス排出量の13.2%を占めると試算されている⁴。老朽化により社会インフラがその設計寿命を全うできない場合、更なる自然破壊やCO₂排出を引き起こすことになる。そこで、社会インフラの安全確保および環境影響軽減のために、劣化状態を正確に把握し、不具合発生前もしくは不具合が軽微な段階でメンテナンスを行う、予防保全の重要性が高まっている。国土交通省は2013年、インフラ長寿命化計画を発表し、予防保全が事後保全(不具合発生後の対策実施)に比べて対策費用が5割削減できる試算結果を示すとともに、予防保全の浸透に向けた社会ルール策定や技術開発の支援を開始した⁵。

工業製品については、高環境負荷の代表製品として自動車が挙げられる。2022年末において、四輪乗用車および商用車(トラック、バス等)は日本で約7800万台、世界では15億台以上が運用されている。また、年間では日本で約780万台、世界で約8000万台(2021年)が新車登録されている⁶。このような運用台数の多さから、自動車の環境負荷は他の交通手段と比べて高く、日本では輸送部門におけるCO₂排出量の88%、総排出量の約17%を占める⁷。自動車エンジンはCO₂や汚染物質の排出を最適化し、環境影響が最小限になるように制御適合されているが、劣化などにより燃焼状態が悪化するとそのバランスが崩れ、環境負荷が急増する。したがって、自動車も社会インフラと同様に、予防保全および異常発生時の早期発見が求められる。

社会インフラや工業製品は、運用開始後は内部状態を直接確認することが困難となるため、測定可能なデータを用いて間接的にモニタリングすることが要求される。間接モニタリングを行うためには、支配現象をモデル化してシミュレーションを行うことになるが、与えるパラメータの不確定性の取り扱いが課題となる。実環境における不確定性を持つシステムに対して、適切な境界条件を与えるための手法の確立が望まれる。

1.2 社会インフラおよび工業製品の状態モニタリングにおける問題点

[1] 社会インフラ：海洋鋼構造物

港湾、空港に関する社会インフラとして、海上には金属を構造材とした建築物が建設されている。鋼材はコンクリートに比べて材料が均質かつ軽量であり、加工も容易であるため、複雑形状をした大型構造物を作るのに適した材料である。海洋鋼構造物の一例として、羽田空港 D 滑走路の多摩川河口部⁸や釧路港棧橋⁹には、ジャケット式棧橋構造が用いられている。ジャケット式棧橋構造とは、陸上で巨大なトラス構造物（ジャケット）を組み立て、現地で先行打設した鋼杭にジャケットを被せる方式である。工場で骨組みを作ってから現地据付けを行うことで、施工品質の安定化や工期短縮という利点がある。一方、金属材料は腐食するという特性も併せ持ち、特に海洋鋼構造物は海水という厳しい腐食環境に置かれる。金属の腐食は構造物の寿命を左右する重要な因子であり、そのため構造物の施工時には、30 年程度経過後の改修を前提とした防食が施される。しかし、現場特有の海洋環境や施工不良による異常腐食を検知、防止するためには、定期的に防食状態検査が必要となる。防食状態検査は本来であれば全部位の検査が望ましいが、時間やコストの関係上、現在は各部位を順次検査していき、全部位の検査が完了するまでに 5 年以上かかる場合もある。そのため最悪の場合、その間異常部位の検知が見過ごされる危険性がある。海洋鋼構造物の大型化が進む中、適切な検査品質および間隔を維持していく上では、防食状態を経済的かつ効率的に検査する手法の確立は重要な課題である。

[2] 工業製品：自動車エンジン

自動車部門の CO₂ 排出量については、欧州委員会(European Commission, EC)や米国カリフォルニア州大気資源局(California Air Resources Board, CARB)が規制値策定の議論をリードしており、新車の燃費性能を所定の走行パターンで車種毎に測定し、自動車会社が販売する全車種平均値(フリート平均 CO₂)を規制する形で排出量の削減が図られている。欧州は 2035 年に新車の CO₂ の 100%削減を含んだ包括案 Fit for 55 を承認し、2035 年以降は電気自動車(Battery Electric Vehicle, BEV)、燃料電池車(Fuel Cell Electric Vehicle, FCEV)、水素エンジン車(Hydrogen Internal Combustion Engine, H₂-ICE)および合成燃料(e-Fuel)のみを用いた内燃機関車のみが販売を許可される¹⁰。米国も 2035 年以降はゼロエミッション車(Zero Emission Vehicle, ZEV)のみの販売が認められるが、欧州委員会の定義に加えてプラグインハイブリッド車(Plug-in Hybrid Electric Vehicle, PHEV)も許可対象に含まれており、化石燃料を用いた内燃機関が許容される¹¹。中国も BEV、FCEV、および PHEV と定義される新エネルギー車(New Energy Vehicle, NEV)の導入比率を、2035 年時点で 50%に引き上げる規制を採択した¹²。日本も 2035 年時点で新車販売を電動車 100%とする目標を設定しているが、電動車の定義には米国や中国と同様に PHEV を含む方向で議論が進んでいる¹³。

また、現行規制はどの地域においても走行時の CO₂ 排出のみを考慮する Tank-to-Wheel ベースに基づいているが、欧州では前述の Fit for 55 包括案にて、2025 年末までにライフサイクル(Life Cycle Assessment, LCA)での CO₂ 排出の規制化に向けた試算結果を発表するとしている。また、CO₂ 規制と並んで自動車会社に課せられる汚染物質の排出規制についても、LCA 観点での規制強化が検討されている。2027 年に施行が見込まれる次期排気規制 Euro7 では、規制値の強化に加えて、排気性能の保証期間を現行の 2 倍となる 10 年間もしくは走行距離 20 万 km に延長することが検討されている¹⁴。

エンジン性能の改良のみならず、燃料そのものを CN 化する取り組みも積極的に進められている。e-Fuel は、フィッシャー・トロプシュ (Fischer Tropsch, FT) 法などを用いて再生可能エネルギーと二酸化炭素から合成される燃料であり、液体としての貯蔵や輸送ができ、また既存エンジンに大きな改修なく導入することが可能である。BEV, FCEV, および H₂-ICE と並び、CN に向けた選択肢の 1 つとなり得るとの試算結果がドイツ内燃機関研究組合 FVV より公表されている¹⁵。しかし、e-Fuel を既存燃料に混合した場合は燃焼特性が変化するため、燃料成分のモニタリングが必要となる。このように、自動車業界においてもリアルワールドにおける環境負荷低減が求められており、エンジン性能および燃料成分のモニタリング技術の重要性が一層高まっている。

1.3 本研究のスコープ

Figure 1 に間接モニタリング技術を構成する計算理論、および本研究のスコープを示す。

間接モニタリング技術は現状状態の推定と将来予測に分類される。現状状態の推定について、実世界のシステムには、支配方程式が明確に定まるホワイトボックス型システムと、現象に確率論的現象が含まれ支配方程式が明確に定まらないブラックボックス型システムが存在する。ホワイトボックス型システムは、物理モデルに基づくシミュレーションで現象の表現が可能なシステムであり、システムの線形性に応じて適用される計算方式は更に三種類に分けられる。線形システムに対しては、パラメータの不確定性に正規分布を仮定し、線形物理モデルによるシミュレーションで推定を行う最小分散推定が用いられる。ベイズ推定は、最小分散推定理論をより一般化した方式であり、シミュレーション誤差や測定誤差、境界条件の不確定性等、あらゆる誤差因子の確率分布を融合して最も確からしい推定値を求める方法である。ベイズ推定の定式化を用いると、シミュレーションに少数の非線形パラメータが含まれる場合でも、非線形な入力パラメータを何通りか仮定してシミュレーションを行い、出力結果を仮定した入力パラメータの出現確率で加重平均することで、線形モデルを用いたまま非線形現象の計算が可能である。一方、大多数の入力値と出力値の関係が非線形となる非線形システムに対しては、シミュレーションの出力値と、観測値の確率分布から求まる尤度関数の最大化計算を行う三次元変分法が用いられる。このように、ホワイトボックス型システムに対しては、物理モデルに基づく演繹的な推定手法が活用されている。

これに対してブラックボックス型システムは、物理モデルでの現象表現が困難な実世界のシステムを指す。支配方程式自体が未知である場合と、支配方程式は存在しているが、確率論的現象が含まれておりシステム応答を完全に予測することができない場合があり、工学分野においては後者が多数を占めると考えられる。このようなブラックボックス型システムに対しては、実データを用いて機械学習モデルを構築し、システムの応答から内部状態を推定する、帰納的推定手法が有効である。

将来予測手法としては、データ同化を用いる。データ同化は、観測データと数値モデル双方の情報を統計的に組み合わせ、最適な推定値を求める手法であり、気象学・海洋学の分野で活用されている¹⁶。データ同化には、ある時刻に同時に観測データを入手して、毎時刻推定を行う逐次更新型と、ある期間内の異なる時刻に観測されたデータを用いて、各期間ごとの状態推定を行う固定区間型が存在する¹⁷。本研究では、前者の逐次更新型データ同化を検討対象とする。

線形モデル向けの将来予測には、カルマンフィルタが用いられる。各時刻について、平均値および分散共分散行列の計算を行うのみであり、比較的低い計算負荷でパラメータの時間発展を予測することができる。非線形モデルに対する将来予測には、複数回の計算を通じてパラメータの確率分布を疑似的に表現する粒子法、またはアンサンブルカルマンフィルタが用いられる。

本研究ではホワイトボックス型システムおよびブラックボックス型システム、それぞれに対して間接モニタリング技術を構築する。前半では、海洋鋼構造物の防食状態を対象として、実環境のパラメータ不確定性に対応する物理モデリングおよび逆解析技術を構築する。後半では、データ駆動型の帰納的推定手法として、機械学習を用いて複合現象の本質に迫り、可視化する技術を構築する。

間接モニタリング技術

本研究のスコープ




Figure 1 Overview map of data assimilation and the scope of this research



1.4 適用対象の詳細

Table 1 に海洋鋼構造物と自動車エンジンの特徴をまとめた結果を示す。海洋鋼構造物は、ジャケット構造物を海底に打設した鋼材に固定し、滑走路や棧橋等の港湾施設を保持する製品機能を持つ。羽田空港 D 滑走路の場合、製品ライフタイムは 35 年ごとの防食設備の更新を行う前提で、構造寿命 100 年とされている。使用環境は海水中となり、本研究におけるモニタリング項目は電気防食状態である。電気防食の支配現象としては、海水中の電場および構造物表面付近の電気化学反応が考えられ、電場についてはラプラス方程式で記述される線形場となる。電気防食状態の劣化は設計寿命 35 年に渡り徐々に進行することから、状態モニタリングする際の時間スケールは年単位とし、日々の潮汐変化や台風などの特異事象は検討外とする。間接モニタリングを用いて推定する物理量は、犠牲陽極電流量および構造物表面電位で、測定する物理量は構造物周囲の海水中電位である。測定可能なデータ数としては、羽田空港 D 滑走路の場合、表中に示す 50m 四方のジャケットが約 200 基、各ジャケット 6 本の縦方向鋼材で構成され、全鋼材を 5 年間隔で少なくとも 1 回は検査する必要があることから、鋼材 1 本あたり、鋼材に沿った電位分布を 1 か所測定する程度が限界となっている。したがって、構造物全体の防食状態を推定するには、物理モデルの援用が不可欠であると考えられる。また、間接モニタリングを行う上で問題となる不確定要素としては、海水温度や成分に依存した鋼材表面抵抗の経年変化や、隣接区域からの電流流入出が挙げられる。現状の点検方法は、ダイバーによる目視検査や寸法測定がメインであり、海中の電位分布測定は補助的に行われている¹⁸。海洋鋼構造物の設置数増加や大規模化が進む昨今、検査作業の効率化が課題である。

自動車エンジンは、燃料の燃焼によりクランク軸を回転させ、車輪駆動および車載装置への電源供給することが製品機能となる。標準的な製品ライフタイムは 10~15 年、走行距離にして 15~20 万 km であり、標高や気温といった使用環境はユーザーごとに大きく異なるが、使用保証環境としてはエンジン水温-40~+120℃、標高~5000m 程度とされている。本研究におけるモニタリング項目は燃焼状態であり、今回は点火コイルを用いたモニタリングを行うこととした。支配現象は点火コイルによる放電現象であり、放電時の電圧は Pashley の式¹⁹や Kim の式²⁰で記述される。これらの式は圧力、温度、流速および実験定数で構成される実験式であるため、実際の放電挙動では上記因子が相互に作用して、燃焼サイクル毎にばらつきを生じる。推定の時間スケールは、放電初期の挙動である絶縁破壊が 1 μ s 以下の時間スケールで進行し、1 サイクル当たりの放電期間は最大 5ms 程度となることから、1 μ s~5ms 程度とした。間接モニタリングを用いて推定する物理量は、燃焼サイクル毎の異常燃焼の発生有無とし、測定する物理量は点火コイル電流および電圧である。海洋構造物と異なり、点火コイル信号は燃焼サイクル毎に取得が可能であり、エンジン回転 1200 回転の場合では 1 分間に 600 サイクル分のデータが取得できる。現在はメモリの制約上、点火コイルのデータは記録されていないが、適切な測定デバイスと記憶装置を用いることで、データ駆動型のモデリングを行うのに十分な量のデータ収集が可能になると考えられる。間接モニタリングを行う上で問題となる不確定要素としては、放電時における支配方程式の不確定性が挙げられる。エンジン運転時の環境条件や吸入空気量、燃料噴射量のばらつきなどで、圧力、温度、流速、ガス成分はサイクル毎に変動する。それら複合因子に影響された結果が、点火コイル信号として取得される。支配方程式の寄与度が明確に定義できない場合には、物理モデルによる推定が困難になるため、大量データを活用してデータ駆動型でモデル化を行うアプローチが求められる。現状の燃焼状態の点検方法として、車両上で常時行われるオンボード診断(On Board Diagnosis, OBD)がある²¹。OBD では、空

燃比(Air Fuel ratio, A/F)センサーや回転数センサー等の既存センサーを用いて車両の不具合を検出し、致命的な不具合が検出された場合はエンジン始動が不許可となる。ただし、特定気筒の失火等、かろうじて走行が可能なケースでは、不具合に関連する機能を制限した上、エンジンの始動は許可される。そして運転席パネルに警告灯が点灯し、ドライバに修理店に行くことを促すようになっている。また、日本では2年に1度の車検(新車登録後の初回車検は3年後)が義務付けられており、不具合は最長でも2年以内には発見、対処される。課題として、エンジン構成や運転条件によってはOBDによる燃焼状態診断の精度が低下し、不具合の即時検出が困難となる点が挙げられる。また、現状の量産車では燃料成分については、エタノール/メタノール対応車向けにはアルコールセンサーが装着される²²が、燃料劣化や、アルコール以外の燃料混合には対応しておらず、将来CN燃料への対応には課題が残る。

Table 1 Comparison of operational features for the marine steel structure and the automotive engine

分類	社会インフラ 海洋鋼構造物	工業製品(輸送機器) 自動車エンジン
検討対象		
製品機能	ジャケット構造物を海底に打設した鋼材に固定し、滑走路や栈橋等の港湾施設を保持する。	燃料の燃焼によりクランク軸を回転させ、車輪駆動および車載装置への電源供給する。
設計寿命	30~100年	10~15年, 15~20万km
使用環境	海水中	陸上(水温-40~+120℃, 標高~5000m程度)
モニタリング項目	電気防食状態	燃焼状態
支配現象	海水中 : 電場(ラプラス方程式) 構造物表面 : 電気化学反応	放電 : Kimの式、Pashleyの式 (圧力、温度、流速、ガス成分依存)
時間スケール	年~(供用期間)	1μs~5ms (1サイクル中の放電期間)
推定する物理量	・犠牲陽極電流量 ・構造物表面電位	・異常燃焼の発生有無
測定可能な物理量	構造物周囲の海水電位	点火コイル電流および電圧
測定可能なデータ量	少ない	多い
不確定要素	境界条件(鋼材表面状態、隣接区域の影響等)	支配方程式(複数物理量の相互作用)
従来の点検方法	ダイバーによる目視検査/寸法測定	・車載既存センサによる燃焼診断(OBD) ・車検時の検査(2年おき)

1.5 研究目的

本研究では、不確定因子を含む系に対する間接モニタリング技術を、ホワイトボックス型システムに分類される海洋鋼構造物の電気防食状態モニタリングと、ブラックボックス型システムに分類される自動車エンジン燃焼モニタリングを対象として構築する。Table 2 に本研究で検討する間接モニタリング技術の比較を示す。海洋鋼構造物に対しては、実環境のパラメータ不確定性に対応する物理モデリングおよび逆解析技術を構築する。物理モデルに基づく演繹的推定手法が取られるホワイトボックス型システムでは、モデルの境界条件の不確定性が課題である。そこで、海洋環境を表現可能な高自由度モデリング、先験情報を積極的に利用したベイズ推定、そして時間軸情報を蓄積/活用するデータ同化について検討する。エンジンに対しては、複合現象の本質に迫り、可視化する技術を構築する。機械学習に基づく帰納的推定手法が取られるブラックボックス型システムでは、支配現象自体が不確定であることが課題となる。そこで、位相面を用いた現象の上位概念化と、判断根拠を説明可能な深層学習モデル構築について検討する。

Table 2 Comparison of the investigated technologies in this dissertation

間接モニタリング 技術	実問題における不確定性を考慮した間接モニタリング技術	
	実環境のパラメータ不確定性に対応する 物理モデリングおよび逆解析技術	複合現象の本質に迫り、 可視化する技術
対象システム	ホワイトボックス型システム	ブラックボックス型システム
不確定因子	境界条件	支配方程式
提案アプローチ	物理モデルに基づく演繹的推定手法	機械学習に基づく帰納的推定手法
研究目的	海洋鋼構造物の電気防食状態の モニタリング	エンジン燃焼状態のモニタリング
[ベース理論]	ベイズ推定，データ同化	機械学習 (深層学習，画像認識)

1.6 本論文の構成

Figure 2 に本論文の構成を示す．第 1 章では，本研究の背景および目的について述べる．第 2 章では従来研究として，データ同化と機械学習の概要，および海洋構造物の電気防食状態と自動車エンジンの燃焼状態のモニタリング技術の文献調査結果と現状課題を示す．第 3,4 章では海洋鋼構造物を対象として，演繹的アプローチに基づく推定手法を検討した結果を示す．第 5 章では自動車エンジンを対象として，帰納的アプローチに基づく推定手法の検討結果を示す．第 6 章では各章のまとめと今後の展望について述べる．




Figure 2 Structure of this dissertation

第2章 従来研究

本章では、データサイエンス技術(データ同化、機械学習)の概要と、海洋鋼構造物の防食状態および自動車エンジンの燃焼状態モニタリング技術についての文献調査結果と現状課題を示す。

2.1 データ同化

2.1.1 データ同化の概要と歴史

Figure 3 にデータ同化の概念図を示す。 x, y はそれぞれ推定値、観測値を表しており、同じ次元の物理量である必要はない。また $x_{(t|t-1)}$ は時刻 $t-1$ までの観測値から推定された時刻 t における推定値であり、 y_t は時刻 t における観測値である。まず、時刻 $t-1$ における推定値 $x_{(t-1|t-1)}$ から、システムモデルにより時刻 t における推定値 $x_{(t|t-1)}$ を予測する。次に時刻 t における観測値 y_t を取得する。そして双方のデータを同化して、修正された推定値 $x_{(t|t)}$ を得る。時刻 $t+1$ 以降についても同様に、予測、修正を繰り返し、推定結果を現実に近づけていく。なお本研究では、システムモデルにより先の時刻における状態を推定することを将来予測、予測結果を観測値に基づき補正することをフィルタリングと呼ぶ。




Figure 3 Concept of data assimilation

データ同化に関連する技術が最初に適用されたのは、1801年に Gauss が、最小二乗法を用いて準惑星セレスの起動パラメータの予測に成功したとされている²³。その後、1940年代に発表された時系列データのフィルタリング理論である Kolmogorov-Wiener Filter は、最適制御理論の基礎となった²⁴。1960年には Kalman が²⁵、1961年には Kalman および Bucy が非定常時系列データへのフィルタリング理論を構築²⁶し、1960年代の米国における宇宙開発へ適用された²⁷。

気象分野におけるデータ同化の活用は、気象衛星の打上げ等により観測データ数が増加した1990年代に検討が加速した。Ghil らは気象学と海洋学におけるデータ同化の適用可能性についてまとめている²⁸。蒲地らは、観測データのうちモデルの持つ力学を満たすもののみを取り出してモデルを改良するデータ同化方法(アジョイント法)を紹介している²⁹。Anderson らは、海洋データの同化における主要アプローチをまとめるとともに、広大な海洋における水中データ取得が課題となることを示した³⁰。2004年には気象庁がデータ同化を用いた数値計算により、十数年に一度発生するとされる黒潮の大蛇行現象の予測に成功した³¹。

その後もデータ同化は気象および海洋分野での適用領域の拡大，また他分野への横展開が進んでいる．川崎らは海洋データ同化システムの活用により，伊勢湾にて夏季に発生する貧酸素水塊発生現象の現象解明を行った³²．田中らは GPS 可降水量の同化による局地的な強雨の予測精度改善を示した³³．珠玖らは地盤解析にデータ同化および粒子フィルタを適用し，神戸空港の将来沈下量の予測を行った³⁴．

2.1.2 データ同化の基礎理論

[1] シミュレーションにおける不確定性の考え方

Figure 4 に決定論的モデルと確率論的モデルの比較を示す³⁵． $\mathbf{x}_t$ を時刻 t における状態変数からなるベクトル， $\mathbf{f}_t$ を $\mathbf{x}_{t-1}$ の時間発展を与えるシミュレーションとする． $\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_{t-1})$ は，初期条件 $\mathbf{x}_0$ を与えてシミュレーション計算を行うと，次の状態 $\mathbf{x}_1$ は一意に定まることを示す．つまり 1 つの入力値に対応する 1 つの出力値が存在し，何度計算を行っても出力結果は不変である．確率分布上で表現すると，シミュレーションの出力はデルタ関数 $p(\mathbf{x}_t|\mathbf{x}_{t-1}) = \delta(\mathbf{x}_t - \mathbf{f}_t(\mathbf{x}_{t-1}))$ のように記述される．このことから，シミュレーションモデルは決定論的であると言える．一方で，初期条件に不確定性があり，1 つの値に定まらない場合は，入力値は幅を持った確率分布となる．この場合，シミュレーションの出力は確率分布 $p(\mathbf{x}_t|\mathbf{x}_{t-1})$ のように表され，この確率論的なシミュレーションモデルをシステムモデルと呼ぶ．データ同化では確率論的考え方に基づき，シミュレーションと観測データとの関係を不確定性を持った状態で表現し，前者をシステムモデル，後者を観測モデルと呼び，両者を組み合わせたものを状態空間モデルと呼ぶ．

決定論的モデル(解は一つに定まる)

確率論的モデル(解は確率分布)




Figure 4 Comparison of a deterministic model and a stochastic model³⁵

[2] システムモデル

ここでは、システムモデルでの不確定性の取り扱いおよび定式化について説明する。

[2.1] 初期条件の不確定性

シミュレーションの初期値 $\mathbf{x}_0$ が不確定性を持ち、その近似値を $\hat{\mathbf{x}}_0$ と表すことにすると、式(1)の関係が成り立つ。

$$\mathbf{x}_0 \cong \hat{\mathbf{x}}_0 \quad (1)$$

これをシミュレーションへ入力し、次の時刻 $t = 1$ における状態ベクトル $\mathbf{x}_1$ を求めると、式(2)のようになる。

$$\mathbf{x}_1 = \mathbf{f}_1(\mathbf{x}_0) \cong \mathbf{f}_1(\hat{\mathbf{x}}_0) = \hat{\mathbf{x}}_1 \quad (2)$$

時刻 $t = 2, 3, \dots, T$ まで順次計算していくと、時刻 T における状態ベクトル $\mathbf{x}_T$ は式(3)となる。

$$\mathbf{x}_T \cong \mathbf{f}_T(\hat{\mathbf{x}}_{T-1}) \quad (3)$$

ここで、近似等号で表される初期条件 $\hat{\mathbf{x}}_0$ を確率分布に置き換えて考える。初期条件は確率分布 $p(\mathbf{x}_0|\hat{\mathbf{x}}_0)$ に従うものとし、前述と同じように時刻 $t = 1, 2, 3, \dots, T$ までの時間発展を追う。近似初期条件 $\hat{\mathbf{x}}_0$ の下での $\mathbf{x}_1$ の確率分布は、 $\mathbf{x}_0, \mathbf{x}_1$ の同時分布 $p(\mathbf{x}_0, \mathbf{x}_1|\hat{\mathbf{x}}_0)$ を $\mathbf{x}_0$ について周辺化することで式(4)のように表せる。

$$p(\mathbf{x}_1|\hat{\mathbf{x}}_0) = \int p(\mathbf{x}_0, \mathbf{x}_1|\hat{\mathbf{x}}_0) d\mathbf{x}_1 = \int p(\mathbf{x}_1|\mathbf{x}_0)p(\mathbf{x}_0|\hat{\mathbf{x}}_0) d\mathbf{x}_0 \quad (4)$$

近似初期条件 $\hat{\mathbf{x}}_{T-1}$ の下での $\mathbf{x}_T$ の確率分布は、式(5)となる。

$$p(\mathbf{x}_T|\hat{\mathbf{x}}_0) = \int p(\mathbf{x}_T|\mathbf{x}_{T-1})p(\mathbf{x}_{T-1}|\hat{\mathbf{x}}_0) d\mathbf{x}_{T-1} \quad (5)$$

上記の式より、シミュレーションの初期条件が確率分布 $p(\mathbf{x}_0|\hat{\mathbf{x}}_0)$ で表される不確定性を持つ場合、計算の結果得られる出力も確率分布 $p(\mathbf{x}_1|\hat{\mathbf{x}}_0), \dots, p(\mathbf{x}_T|\hat{\mathbf{x}}_0)$ で表される不確定性を持つこととなる。

[2.2] 時間発展の不確定性

初期条件に続いて、時間発展における不確定性を考える。シミュレーション $\mathbf{f}_t$ が不確定性を持つ場合、式(3)と同様に、式(6)が成り立つ。

$$\mathbf{x}_t \cong \mathbf{f}_t(\mathbf{x}_{t-1}) \quad (6)$$

時間発展の不確定性に起因する誤差であるシステムノイズ $\mathbf{v}_t$ を加えて、近似等号を等号化すると、式(7)となる。

$$\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_{t-1}) + \mathbf{v}_t \quad (7)$$

$\mathbf{v}_t$ の確率分布を $p(\mathbf{v}_t)$ とすると、 $\mathbf{x}_{t-1}$ が与えられた下での $\mathbf{x}_t$ は式(8)のように表せる。

$$p(\mathbf{x}_t|\mathbf{x}_{t-1}) = \int p(\mathbf{x}_t, \mathbf{v}_t|\mathbf{x}_{t-1})d\mathbf{v}_t = \int p(\mathbf{x}_t|\mathbf{v}_t, \mathbf{x}_{t-1})p(\mathbf{v}_t|\mathbf{x}_{t-1})d\mathbf{v}_t \quad (8)$$

[2.3] システムモデルの定式化

最後に、初期条件の不確定性および時間発展の不確定性をまとめて表現する。初期条件 $\mathbf{x}_0$ の確率分布を式(9)、システムノイズ $\mathbf{v}_t$ の確率分布を式(10)とすると、システムモデルは式(11)となる。

$$\mathbf{x}_0|\hat{\mathbf{x}}_0 \sim p(\mathbf{x}_0|\hat{\mathbf{x}}_0) \quad (9)$$

$$\mathbf{v}_t \sim p(\mathbf{v}_t) \quad (t = 1, \dots, T) \quad (10)$$

$$\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_{t-1}) + \mathbf{v}_t \quad (11)$$

[3] 観測モデル

ここでは、観測値の不確定性の取り扱いおよび観測方程式の定式化について説明する。

[3.1] 観測行列と観測演算子

$\mathbf{y}_t$ は時刻 t において観測される物理量をまとめた観測ベクトルである。まず、システムモデルにより得られた状態ベクトル $\mathbf{x}_t(t = 1, \dots, T)$ の時系列データ $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T$ と、観測ベクトル $\mathbf{y}_t$ の時系列データ $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T$ を比較する。 $\mathbf{x}_t$ は k 次元ベクトル、 $\mathbf{y}_t$ は l 次元ベクトルとすると、多くの場合は $k > l$ 、すなわち状態ベクトル $\mathbf{x}_t$ に対して、実際に観測できるデータ量は少なくなる。状態ベクトル $\mathbf{x}_t$ の一部が観測される場合、状態の全変量から観測される変量を取り出すような l 行 k 列の観測行列 H_t を定義する。 $\mathbf{x}_t$ と $\mathbf{y}_t$ が同じ単位の物理量の場合、観測行列は状態ベクトル $\mathbf{x}_t$ から観測ベクトル $\mathbf{y}_t$ に該当する値を抽出するための行列となるため、その成分は0と1のみとなる。

次に、モデルの一部に非線形変換された値が観測される場合を考える。このときは、観測行列の代わりに観測演算子 $\mathbf{h}_t$ を導入する。状態ベクトル $\mathbf{x}_t$ を観測ベクトル $\mathbf{y}_t$ に変換するための支配方程式を観測演算子として用いることで、観測ベクトル $\mathbf{y}_t$ が状態ベクトル $\mathbf{x}_t$ と異なる単位の物理量であっても取り込むことが可能となる。

[3.2] 観測の取り込み

システムモデルと観測ベクトル $\mathbf{y}_t$ の比較を考える。システムモデルからは状態ベクトル $\mathbf{x}_t$ の確率分布の列 $p(\mathbf{x}_t)(t = 1, \dots, T)$ が得られ、観測対応量 $\mathbf{h}_t(\mathbf{x}_t)$ も確率分布の列 $p(\mathbf{h}_t(\mathbf{x}_t))(t = 1, \dots, T)$ となる。このような不確定性のあるモデル結果を、確定した観測データ $\mathbf{y}_t$ と比較するために、確率分布 $p(\mathbf{h}_t(\mathbf{x}_t))$ と $\mathbf{y}_t$ の整合性を検証する。システムモデルと観測値 $\mathbf{y}_t$ を比較する場合は、モデルの観測対応量の確率分布と観測

値の比較となり，点と分布を突き合わせることになる．確率分布の中で，確率の高い部分に $\mathbf{y}_t$ が入っていれば，モデルの推定結果は妥当と判断できる．

システムモデルでは確率分布が得られ，状態の不確定性を表す．ここに観測データを取り込むことで，状態の確率分布 $p(\mathbf{x}_t|\mathbf{x}_0)$ を修正し不確実の度合いを下げる，すなわち推定精度を向上させることが可能となる．

[3.3] 観測モデルと観測ノイズ

観測データ $\mathbf{y}_t$ とモデルによる観測変量 $\mathbf{h}_t(\mathbf{x})$ は一般には一致しないが，両者は近い値であると考えられる．両者の関係は式(12)のように表される．

$$\mathbf{y}_t \cong \mathbf{h}_t(\mathbf{x}_t) \quad (12)$$

システムモデルの際と同様に，近似等号に代わり観測ノイズ項 $\mathbf{w}_t(t = 1, \dots, T)$ を導入して式(12)を等号で結ぶと，式(13)および式(14)のようになる．式(13)を観測モデルと呼ぶ．

$$\mathbf{y}_t = \mathbf{h}_t(\mathbf{x}_t) + \mathbf{w}_t \quad (13)$$

$$\mathbf{w}_t \sim p(\mathbf{w}_t) \quad (14)$$

[4] 状態空間モデル

データ同化では，システムモデル式(11)と観測モデル式(13)を連立させ，両者を交互に実施していく．このような連立モデルを状態空間モデルと呼ぶ．状態空間モデルの運用には，初期状態 $\mathbf{x}_0$ ，システムノイズ $\mathbf{v}_0$ ，および観測ノイズ $\mathbf{w}_0$ の確率分布 p を用いる．それぞれの定義式を式(15)(16)(17)に示す．

$$\mathbf{x}_0 \sim p(\mathbf{x}_0) \quad (15)$$

$$\mathbf{v}_0 \sim p(\mathbf{v}_0) \quad (16)$$

$$\mathbf{w}_0 \sim p(\mathbf{w}_0) \quad (17)$$

2.1.3 データ同化の計算手順

Figure 5 にデータ同化による状態推定フローを示す． $p(\mathbf{x}_j|\mathbf{y}_{1:k})$ は時刻 1 から k までの観測データに基づいた，時刻 j における状態ベクトル $\mathbf{x}_j$ の確率分布である． $p(\mathbf{x}_{t-1}|\mathbf{y}_{1:t-1})$ は時刻 1 から $t-1$ までの観測データ $\mathbf{y}_{1:t-1}$ から同時刻における状態ベクトル $\mathbf{x}_{t-1}$ を推定している．予測を行うと，観測データの時刻はそのままに，次の時刻 t における状態ベクトル $\mathbf{x}_t$ の確率分布 $p(\mathbf{x}_t|\mathbf{y}_{1:t-1})$ が得られる．次にフィルタリングを行うと，観測データの時刻が更新され，時刻 1 から t までの観測データ $\mathbf{y}_{1:t}$ を用いた時刻 t における状態ベクトル $\mathbf{x}_t$ の確率分布 $p(\mathbf{x}_t|\mathbf{y}_{1:t})$ が得られる．このように予測とフィルタリングを繰り返すことで，観測値を逐次的に取り込みながら，将来状態を予測していくことができる．以下では，観測データを用いたフィルタリングおよびシステムモデルによる予測について，代表的な手法を説明する．




Figure 5 Flow chart of the state estimation by data assimilation³⁵

[1] フィルタリング(同化)

フィルタリングは、線形モデル向けの最小分散推定と、非線形モデルにも対応した最尤推定法がある。

[1.1] 最小分散推定

2 つの異なる推定値 x_1, x_2 から、最適推定値 x_a を求める。変数 x の真値を x^t 、推定値 x_1, x_2 の誤差を ϵ_1, ϵ_2 とすると、式(18)(19)のように表すことができる。

$$x_1 = x^t + \epsilon_1 \quad (18)$$

$$x_2 = x^t + \epsilon_2 \quad (19)$$

ここで、次の 2 つの条件を仮定する。

1. x_1, x_2 の期待値は真値 x^t と等しい。期待値を $\langle \rangle$ で表すと、次の関係式(20)(21)が成り立つ。

$$\langle x_1 \rangle = \langle x_2 \rangle = x^t \quad (20)$$

$$\langle \epsilon_1 \rangle = \langle \epsilon_2 \rangle = 0 \quad (21)$$

2. x_1 と x_2 の誤差は無相関であり、式(22)が成り立つ。また式(22)に式(18)(19)を代入すると式(23)が得られる。

$$\langle (x_1 - x^t)(x_2 - x^t) \rangle = 0 \quad (22)$$

$$\langle \epsilon_1 \epsilon_2 \rangle = 0 \quad (23)$$

以上の仮定の下で、最適値 x_a を、 x_1, x_2 、および重み α を用いた線形結合で表すと、式(24)となる。

$$x_a = \alpha x_1 + (1 - \alpha) x_2 \quad (24)$$

これより、 x_a の誤差分散 σ_a^2 は次の式(25)で表される。 σ_1^2, σ_2^2 はそれぞれ x_1, x_2 の誤差分散であり、事前

情報などからあらかじめ見積もっておく必要がある。

$$\sigma_a^2 = \langle (x_a - x^t)^2 \rangle = \alpha^2 \sigma_1^2 + (1 - \alpha)^2 \sigma_2^2 \quad (25)$$

σ_a^2 を最小化する重み α は式(26)のように求めることができる。

$$\alpha = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (26)$$

最適推定値 x_a は式(27)、および誤差分散 σ_a^2 は式(28)のようになる。

$$x_a = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} x_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} x_2 = x_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} (x_2 - x_1) \quad (27)$$

$$\sigma_a^2 = \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 + \sigma_2^2} \quad (28)$$

x_1, x_2 の線形結合で表される推定値の誤差分散を最小化する重みを求める方法を、最小分散推定と呼ぶ。

[1.2] 最尤推定(変分法)

ここでは、推定値 x_1, x_2 が適当な確率密度分布に従う確率変数として、最適推定値 x_a を求める。以下の3点を仮定する。

1. x_1, x_2 は正規分布に従う
2. x_1, x_2 は不偏推定値である
3. x_1, x_2 は独立である

条件 1.および 2.から、 x_1, x_2 の確率密度分布は次の式(29)(30)のように書ける。

$$p(x_1|x^t) = \frac{1}{\sqrt{2\pi}\sigma_1} \exp\left[-\frac{(x_1 - x^t)^2}{2\sigma_1^2}\right] \quad (29)$$

$$p(x_2|x^t) = \frac{1}{\sqrt{2\pi}\sigma_2} \exp\left[-\frac{(x_2 - x^t)^2}{2\sigma_2^2}\right] \quad (30)$$

条件 3.より、 x_1, x_2 が同時に実現される確率密度分布 $p(x_1, x_2|x^t)$ は、2つの確率密度分布の積で表すことができる。これを $L(x^t|x_1, x_2)$ として式(31)のように表記する。

$$L(x^t|x_1, x_2) = p(x_1, x_2|x^t) = p(x_1|x^t)p(x_2|x^t) \quad (31)$$

ここで、真値 x^t を変数 x と表記すると、式(31)は以下の式(32)と表せる。

$$L(x|x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2} \exp \left[-\frac{(x_1 - x)^2}{2\sigma_1^2} - \frac{(x_2 - x)^2}{2\sigma_2^2} \right] \quad (32)$$

$L(x|x_1, x_2)$ はある真値 x を仮定したとき、 x_1, x_2 が同時に観測される確率を表し、尤度関数と呼ばれる。尤度関数を最大化するために、引数にマイナスをかけた次式(33)を最小化する問題に帰着する。

$$J(x) = \frac{(x_1 - x)^2}{2\sigma_1^2} + \frac{(x_2 - x)^2}{2\sigma_2^2} \quad (33)$$

式(33)を最小化することで最適推定値および誤差分散を求める手法を、最尤推定法と呼ぶ。最小分散推定は適用可能なモデルは線形かつ確率分布が正規分布のケースに限られるが、最尤推定法は非線形モデルにも対応可能である。なお、変数 x が正規分布に従うと仮定すると、最小分散推定と最尤推定法から導かれる最適値は一致する。

[2] 将来予測(時間発展)

次に、システムモデルを用いた将来予測手法について説明する。線形モデル向けにはカルマンフィルタ(Kalman Filter, KF)が用いられる。システムモデルと観測モデルがともに線形で、システムノイズと観測ノイズがガウス分布である場合に適用が可能である。非線形モデルを扱う手法としては、拡張カルマンフィルタ(Extended Kalman Filter, EKF)、アンサンブルカルマンフィルタ(Ensemble Kalman Filter, EnKF)、粒子フィルタ(Particle Filter, PF)等がある。拡張カルマンフィルタは、各状態変数周りで線形化を行いカルマンフィルタの式を適用可能とする方法であるが、巨大システムは線形化が困難、または計算が不安定になる問題がある。アンサンブルカルマンフィルタは、モンテカルロ近似を用いて、線形化を行うことなく分散共分散行列の大きさを推定することができる。さらに、状態の確率分布に非ガウス性がある、または観測データがポアソン分布、二項分布などの離散分布に従う場合には、線形性・ガウス性の仮定が不要な粒子フィルタが用いられる。各手法の概要を以下に示す。

[2.1] カルマンフィルタ

カルマンフィルタは線形な観測方程式を持つモデルを対象とした推定手法で、2つの計算過程で成り立っている。1つは観測データを用いて、前述の最小分散推定理論に基づいて観測データや数値計算の結果から最適な推定値を得る、フィルタリング計算である。もう一つが、システムモデルに基づいて推定値および誤差分散の時間発展を計算する、将来予測である。まず、システムモデル式(11)と観測モデル式(13)で構成される状態空間モデルを線形化すると、それぞれ式(34)(35)のようになる。

$$\mathbf{x}_t = \mathbf{F}_t \mathbf{x}_{t-1} + \mathbf{G}_t \mathbf{v}_t \quad (34)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t \quad (35)$$

$\mathbf{x}_t$ は k 次元の状態ベクトル、 $\mathbf{v}_t$ はシステムノイズで、平均ベクトル $\mathbf{0}$ 、分散共分散行列 $\mathbf{Q}_t$ のガウス分布

に従う m 次元ベクトルである。 $\mathbf{w}_t$ は観測ノイズで、平均ベクトル 0、分散共分散行列 R_t のガウス分布に従う l 次元ベクトルである。 シミュレーションモデル F_t は線形で、観測行列 H_t は状態ベクトルの線形変換で対応する観測量が得られることを示している。 G_t はガウス分布に従うシステムノイズ $\mathbf{v}_t$ の線形変換量により、時間発展の不確定性 $\mathbf{x}_t - F_t \mathbf{x}_{t-1}$ を表せることを示している。 このように、 F_t 、 G_t 、 H_t が全て線形な行列であり、 $\mathbf{v}_t$ 、 $\mathbf{w}_t$ がガウス分布に従うことから、このモデルは線形・ガウス状態空間モデルと呼ばれる。

式(34)の線形システムモデルによる将来予測を考える。 状態ベクトル $\mathbf{x}_t$ および分散共分散行列 V_t の時間発展は、式(36)(37)のように記述される。

$$\mathbf{x}_{t|t-1} = F_t \mathbf{x}_{t-1|t-1} \quad (36)$$

$$V_{t|t-1} = F_t V_{t-1|t-1} F_t' + G_t Q_t G_t' \quad (37)$$

また、観測データを用いたフィルタリングでは、最小分散推定理論に基づき、下記の観測更新式(38)(39)(40)が得られる。 式(40)をカルマンゲインと呼ぶ。

$$\mathbf{x}_{t|t} = \mathbf{x}_{t|t-1} + K_t (\mathbf{y}_t - H_t \mathbf{x}_{t|t-1}) \quad (38)$$

$$V_{t|t} = V_{t|t-1} - K_t H_t V_{t|t-1} \quad (39)$$

$$K_t = V_{t|t-1} H_t' (H_t V_{t|t-1} H_t' + R_t)^{-1} \quad (40)$$

将来予測式およびフィルタリング式を交互に計算することで、状態の確率分布を追うことが可能となる。 **Figure 6** にカルマンフィルタの計算イメージの図を示す。 時刻 $t-1$ におけるフィルタ分布から、次の時刻 t における状態量を予測する。 システムモデルの不確定性から、予測値の分散共分散行列は大きくなり、確率分布は横に広がる。 次に、観測値 $\mathbf{y}_t$ をフィルタリング操作により同化させ、時刻 t におけるフィルタ分布を得る。 観測データによる同化の分、推定精度が向上し、時刻 t のフィルタ分布の分散共分散行列が小さくなる。 すなわち、確率分布の横方向の広がり量が低減する。




Figure 6 Images of Kalman Filter³⁵

[2.2] 拡張カルマンフィルタ

システムモデルを非線形、観測モデルは線形として、状態空間モデル(41)(42)を考える.

$$\mathbf{x}_t = \mathbf{f}_t(\mathbf{x}_{t-1}, \mathbf{v}_t) \quad (41)$$

$$\mathbf{y}_t = \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t \quad (42)$$

非線形モデルである式(41)にカルマンフィルタの式を適用するために、状態 $\mathbf{x}_{t-1}$ と $\mathbf{v}_t$ の平均値 $\mathbf{x}_{t-1|t-1}$ 、 $\hat{\mathbf{v}}_t$ の周りで線形化し、線形システムモデル(34)の形にすることが考えられる. 線形化を行うには、下で表されるヤコビ行列(43)(44)を計算する.

$$\hat{\mathbf{F}}_t = \left. \frac{\partial \mathbf{f}_t}{\partial \mathbf{x}'_{t-1}} \right|_{(\mathbf{x}_{t-1}, \mathbf{v}_t) = (\mathbf{x}_{t-1|t-1}, \hat{\mathbf{v}}_t)} \quad (43)$$

$$\hat{\mathbf{G}}_t = \left. \frac{\partial \mathbf{f}_t}{\partial \mathbf{v}'_t} \right|_{(\mathbf{x}_{t-1}, \mathbf{v}_t) = (\mathbf{x}_{t-1|t-1}, \hat{\mathbf{v}}_t)} \quad (44)$$

そして、式の更新式(45)(46)を用いて将来予測を行う. フィルタリングについては、線形モデルのため、式(37)と同じとなる. もし観測モデルが非線形の場合は、システムモデル同様に線形化を行う.

$$\mathbf{x}_{t|t-1} = \mathbf{f}_t(\mathbf{x}_{t-1|t-1}, \hat{\mathbf{v}}_t) \quad (45)$$

$$\mathbf{V}_{t|t-1} = \hat{\mathbf{F}}_t \mathbf{V}_{t-1|t-1} \hat{\mathbf{F}}_t' + \hat{\mathbf{G}}_t \mathbf{Q}_t \hat{\mathbf{G}}_t' \quad (46)$$

このような部分線形化による非線形モデル計算手法を拡張カルマンフィルタと呼ぶ. 拡張カルマンフィルタでは、解析的に微分ができない場合に数値微分を行う必要があり、 $\mathbf{x}_{t-1}$ の次元が大きい場合は数値微分が困難となり、式(46)が不安定になる可能性がある.

[2.3] アンサンブルカルマンフィルタ

アンサンブル近似を用いて分布形状を近似することで、確率分布を表現することを考える. ある確率変数 $\mathbf{x}$ の確率分布を、 N 個のサンプルの集合 $\{\mathbf{x}^{(i)}\}_{i=1}^N$ を用いて、以下の式(47)のように近似する.

$$\mathbf{p}(\mathbf{x}) \doteq \frac{1}{N} \sum_{i=1}^N \delta(\mathbf{x} - \mathbf{x}^{(i)}) \quad (47)$$

ここで $\doteq$ はアンサンブル近似を表す. またサンプル集合 $\{\mathbf{x}^{(i)}\}_{i=1}^N$ をアンサンブル、各 $\mathbf{x}^{(i)}$ をアンサンブルメンバーまたは粒子と呼ぶ. N はアンサンブルメンバー数または粒子数と呼ばれる. **Figure 7** にアンサンブルカルマンフィルタの1次元の場合のイメージ図を示す. 連続関数である確率密度関数を、 N 個のデルタ関数の和で近似している. カルマンフィルタでは平均値と分散共分散行列を式(36)(37)に基づき逐次的に計算をするが、アンサンブルカルマンフィルタでは、予測分布とフィルタ分布のアンサンブルを逐次的に計算していく.




Figure 7 Images of Ensemble Kalman Filter³⁵

システムモデルによる将来予測を考える．状態ベクトル $\mathbf{x}_t$ のアンサンブルメンバー $\mathbf{x}^{(i)}$ をシステムモデルに基づいて更新し，予測分布のアンサンブル $\{\mathbf{x}_{t|t-1}^{(i)}\}_{i=1}^N$ を得る．各アンサンブルメンバーの状態ベクトル $\mathbf{x}_{t|t-1}^{(i)}$ およびシステムノイズ $\mathbf{v}_t^{(i)}$ は式(48)(49)のように表される．

$$\mathbf{x}_{t|t-1}^{(i)} = \mathbf{f}_t(\mathbf{x}_{t-1|t-1}^{(i)}, \mathbf{v}_t^{(i)}) \quad (48)$$

$$\mathbf{v}_t^{(i)} \sim q_t(\mathbf{v}_t) \quad (49)$$

計算実行時はまず，乱数を用いて式(49)によりシステムノイズのアンサンブル $\{\mathbf{v}_t^{(i)}\}_{i=1}^N$ を生成する．そして，各アンサンブルに対して式(48)を計算する．計算に際して $\mathbf{f}_t$ は線形化する必要がない，またアンサンブルの計算結果から分散共分散行列を算出することができるので，拡張カルマンフィルタに比べて計算負荷の軽減や，計算安定性の向上が見込める．

観測データを用いたフィルタリングでは，予測分布のアンサンブルから，観測データを同化したフィルタ分布を得る．まず，状態ベクトルおよび観測ノイズのサンプル分散共分散行列 $\hat{\mathbf{V}}_t$ ， $\hat{\mathbf{R}}_t$ を計算する．式(50)を用いて，アンサンブルメンバー $\mathbf{x}_{t|t-1}^{(i)}$ の擾乱ベクトル $\tilde{\mathbf{x}}_{t|t-1}^{(i)}$ を計算する．そして，式(51)へ代入することで，状態ベクトルの分散共分散行列 $\hat{\mathbf{V}}_{t|t-1}$ を得る．

$$\tilde{\mathbf{x}}_{t|t-1}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{x}_{t|t-1}^{(j)} \quad (50)$$

$$\hat{\mathbf{V}}_{t|t-1} = \frac{1}{N-1} \sum_{j=1}^N \tilde{\mathbf{x}}_{t|t-1}^{(i)} \tilde{\mathbf{x}}_{t|t-1}^{(i)'} \quad (51)$$

次に，乱数を用いて式(52)を計算し，観測ノイズのアンサンブル $\{\mathbf{w}_t^{(i)}\}_{i=1}^N$ を生成する．そして，各アンサンブルに対して式(53)を計算することで，観測ノイズのサンプル分散共分散行列 $\hat{\mathbf{R}}_t$ を得る．

$$\tilde{\mathbf{w}}_t^{(i)} = \mathbf{w}_t^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{w}_t^{(j)} \quad (52)$$

$$\hat{R}_t = \frac{1}{N-1} \sum_{j=1}^N \tilde{\mathbf{w}}_t^{(j)} \tilde{\mathbf{w}}_{t|t}^{(j)'} \quad (53)$$

以上の結果より、式(54)によりカルマンゲイン $\hat{K}_t$ を計算し、式(55)によりフィルタ分布のアンサンブルメンバー $\mathbf{x}_{t|t}^{(i)}$ を得る。

$$\hat{K}_t = \hat{V}_{t|t-1} H_t' (H_t \hat{V}_{t|t-1} H_t' + \hat{R}_t)^{-1} \quad (54)$$

$$\mathbf{x}_{t|t}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} + \hat{K}_t (\mathbf{y}_t + \tilde{\mathbf{w}}_t^{(i)} - H_t \mathbf{x}_{t|t-1}^{(i)}) \quad (55)$$

将来予測とフィルタリングを交互に計算することで、状態の確率分布を推定していく。なお、線形なシステムモデルおよび観測モデル、そして初期分布とノイズの分布にガウス分布を与え、アンサンブルメンバー数を無限大に増加させた場合、アンサンブルカルマンフィルタを用いて得られる状態ベクトルの平均値および分散共分散行列は、カルマンフィルタを用いた場合の推定値に一致することが知られている。したがって、アンサンブルカルマンフィルタは、線形モデルに対してはカルマンフィルタとの整合性を持ちつつ、非線形モデルにも対応したアルゴリズムであると言える。ただし、アンサンブルメンバー数の分だけ計算を繰り返し実行する必要があるため計算負荷が増加する。推定を行う対象システムの特性に応じて、適切な推定手法を選択することが必要である。

[2.4] 粒子フィルタ

最後に、より一般的な時系列モデルにも適用可能な粒子フィルタの概要を説明する。粒子フィルタもアンサンブル近似を用いたアルゴリズムであり、将来予測部分についてはアンサンブルカルマンフィルタと全く同じの、式(48)(49)に示される計算を行う。ただしフィルタリングの際に、粒子フィルタにおいては復元抽出と呼ばれる、観測値への一致度が低い粒子を破棄し、代わりに一致度の高い粒子を複製して増やす操作が実施される。フィルタリングにおける計算手順を以下に示す。

フィルタリングに際して、粒子 $\mathbf{x}_{t|t-1}^{(i)}$ の観測値 $\mathbf{y}_t$ への一致度を表す尤度 $\lambda_t^{(i)} = p(\mathbf{y}_t | \mathbf{x}_{t|t-1}^{(i)})$ を計算する。例として、観測モデルが線形、観測ノイズが平均値 0 で分散共分散行列 $\mathbf{R}_t$ に従うガウス分布とすると、尤度の計算式は式(56)で表される。

$$\lambda_t^{(i)} = p(\mathbf{y}_t | \mathbf{x}_{t|t-1}^{(i)}) = \frac{1}{\sqrt{(2\pi)^l |\mathbf{R}_t|}} \exp \left[-\frac{1}{2} (\mathbf{y}_t - H_t \mathbf{x}_{t|t-1}^{(i)})' \mathbf{R}_t^{-1} (\mathbf{y}_t - H_t \mathbf{x}_{t|t-1}^{(i)}) \right] \quad (56)$$

次に、全粒子の尤度の総和における、ある粒子の尤度の割合 $\beta_t^{(i)}$ を式(57)に基づき求める。

$$\beta_t^{(i)} = \frac{\lambda_t^{(i)}}{\sum_{j=1}^N \lambda_t^{(j)}} \quad (57)$$

そして、アンサンブル $\{\mathbf{x}_{t|t-1}^{(i)}\}_{i=1}^N$ から粒子 $\mathbf{x}_{t|t-1}^{(i)}$ が確率 $\beta_t^{(i)}$ で抽出されるよう、復元抽出を N 回実施する。得られた N 個のサンプルを用いて、フィルタ分布を近似するアンサンブル $\{\mathbf{x}_{t|t}^{(i)}\}_{i=1}^N$ を構成する。アンサンブルカルマンフィルタでは、各アンサンブルは途中で消滅や出現することなく、フィルタリングの度に観測データに近い方向へ移動させることでフィルタ分布を生成していた。一方で粒子フィルタでは、尤度の低い粒子を破棄、尤度の高い粒子を複製することで、フィルタ分布を生成する。この仕組みは遺伝的アルゴリズムと類似した手順を持つ手法であると言える。しかしながら、粒子フィルタはフィルタリング操作を繰り返すうちに、特定の粒子の寄与度が増加し確率分布の広がり表現できなくなる、アンサンブルの退化が発生することがある。パラメータ数が大きくなると、退化発生リスクが大きくなる。

2.1.4 本研究におけるデータ同化の適用方針

ここまでで、データ同化の基礎理論を説明した。防食状態シミュレーションにおいては、海洋環境の変動等、実現象を表現できない要素が数多くあるため、データ同化の適用によるシミュレーション予測精度向上を検討する。

2.2 機械学習

2.2.1 機械学習の歴史

機械学習は、人工知能(AI)の基盤となる技術であり、与えられたデータから規則性を見出す技術を用いた予測、分類、認識技術の総称である。総務省によると、AIには確立した定義は存在しないものの、大量の知識データに対して、高度な推論を的確に行うことをめざしたもの、とされている³⁶。また本研究で用いる深層学習は、機械学習のうち多数の層からなるニューラルネットワークを用いるもので、規則性を発見する際の特徴量を自ら抽出することができる技術である。Figure 8 に人工知能、機械学習、および本研究で用いる深層学習の関係を示す。

AI は 1956 年のダートマス会議にて、米国の計算機科学研究者 John McCarthy により提唱され³⁷、1959 年の学会誌“Programs with common sense”では、プログラムに論理的思考を持たせる概念が示されている³⁸。1950~60 年代は AI の探索、推論、自然言語処理への応用が活発に議論され、第 1 次 AI ブームと呼ばれている。Joseph Weizenbaum により開発された、ユーザーの発言に対して事前準備された回答パターンを発話する人工知能プログラム ELIZA が代表例として挙げられる³⁹。

1980 年代には、知識表現に関する技術が開発され、コンピュータが専門家の知識を取り込み、専門家のように振る舞うことが可能となった。これは第 2 次 AI ブームと呼ばれ、Edward Albert Feigenbaum により開発された、血液疾患の診断および抗生物質の推奨を行うエキスパートシステム MYCIN が事例として挙げられる。

1990 年代以降は、機械学習および深層学習を核とする第 3 次 AI が始まった。膨大なデータから分類や予測を行う機械学習や、特徴量を自律的に見出すことのできる深層学習が開発されたことにより、より現実的な問題への対処が可能となっている。2012 年の ILSVRC (Image Net Large Scale Visual Recognition Challenge) コンテストで優勝した、Krizhevsky らが提案した畳み込みニューラルネットワークによる画像認識技術が事例として挙げられる⁴⁰。




Figure 8 Relationship among Artificial Intelligence, Machine Learning, and Deep Learning

2.2.2 機械学習の基礎理論

[1] ニューラルネットワーク

本研究で用いる、階層型ニューラルネットワークについて説明する。Figure 9 に階層型ニューラルネットワークの構造を示す。ニューラルネットワーク(Neural Network, NN)は、人間の脳の仕組みと同様に、神経細胞に当たるノードを相互接続したモデルであり、複数の入力データノードからなる入力層と、1つの出力データノードである出力層、両者をつなぐ中間層(または隠れ層)で構成される。各ノード間には重み係数が設定されており、あるユニットにおける出力値は、接続された他ノードの入力総和を入出力関数に代入した値となる。階層型ニューラルネットワークの場合、信号の伝達方向は一方通行となっており、パターン分類や識別などに用いられる。




Figure 9 Structure of the hierarchical neural network

[2] 学習

学習とは、与えたデータからニューラルネットワークのノード同士をつなぐ重み係数を同定する作業を指す。学習には教師あり学習と教師無し学習、および強化学習がある。教師あり学習は、入力データと正解となる出力データをセットで与えて学習を行う方式であり、ニューラルネットワークは与えたデータを再現できるように学習が進む。教師無し学習では、入力データのみを与えて過去のトレンドと異なる入力データが入った際に異常値として検出させる。強化学習では、データを与える代わりに、出力値に対して報酬を与えるルールを規定する。入力値を変えながら報酬を最大化するように繰り返し計算を行わせるようニューラルネットワークに指示をすることで、モデルが自律的に入力データを作成し、学習が進む。強化学習の例としては、囲碁の基本的ルールを教えた上で、コンピュータ同士の対局を繰り返させることで世界チャンピオンを凌駕する実力を身につけた、Silver らによる AlphaGo がある⁴¹。本研究では、教師あり学習を用いる。

学習において、ニューラルネットワークの重み係数を決定するための計算手順を示す。 N 個のデータサンプルに対する n 番目入力を x_n 、入力値 x_n を与えた時のモデル出力を $y(x_n; w)$ 、ネットワーク内の重み

を w , そして教師データとして与えるネットワーク出力値を d_n とする. ここで誤差関数と呼ばれる, モデル出力と差分の二乗の総和を取り, $1/2$ を掛けた値を, 式(58)により計算する.

$$E(w) = \frac{1}{2} \sum_{n=1}^N [d_n - y(x_n; w)]^2 \quad (58)$$

分類問題の場合, 最終出力層にソフトマックス関数を用いることで, ネットワーク出力値の合計が 1 となり, 判別されたクラスに相当する確率を, 式(59)のように表現することが可能となる.

$$P(C_k|x) = y_k = z_k^{(L)} \quad (59)$$

さらに, 尤度 y_k の対数を取り, 符号を反転させたものを交差エントロピーと呼び, 分類問題の場合の誤差関数は, 式(60)の形でまとめられる. 学習ではこの誤差関数を最小化するように繰り返し計算を行う.

$$E(w) = - \sum_{n=1}^N \sum_{k=1}^K d_n \log y_k(x_n; w) \quad (60)$$

[3] 分類アルゴリズム

式(60)を最小化するために, 数々の最適化手法が提案されている. 一般的には勾配降下法が広く用いられている⁴². 重み w は損失関数の勾配に基づき, 式(61)で更新される. ここで, η は学習係数である.

$$w^{t+1} = w^t - \eta \frac{\partial E(w^t)}{\partial w^t} \quad (61)$$

勾配降下法は, 局所最適解に収束してしまいやすい問題点がある. そこで, 重み w の更新ごとにランダムにサンプルを選び出す確率的勾配降下法(Stochastic Gradient Descent, SGD)が開発された. さらに, 慣性項 $\alpha \Delta w^t$ を付加して, 前ステップの α 倍を掛けて加算することで, パラメータの更新幅を動的に変更して局所最適解への落ち込みを防止するモーメント項付き確率的勾配降下法(Momentum Stochastic Gradient Descent, MSGD)が提案されている⁴³. MSGD の計算式を式(62)に示す.

$$w^{t+1} = w^t - \eta \frac{\partial E(w^t)}{\partial w^t} + \alpha \Delta w^t \quad (62)$$

2.2.3 深層学習

[1] 深層学習の種類

深層学習は、ニューラルネットワークを多層に結合し、関数近似能力を向上させた機械学習手法である。従来の機械学習では入出力データの選定は人が行う必要があったが、深層学習ではデータ分析における特徴量抽出を自動で行うことが可能となる。特徴量の自動抽出手法としては、畳み込みニューラルネットワーク(Convolutional Neural Network, CNN)、リカレントニューラルネットワーク(Recurrent Neural Network, RNN)、敵対的生成ネットワーク(Generative Adversarial Networks, GAN)などがある。畳み込みニューラルネットワークは、人の視覚をモデルに考案されたニューラルネットワーク構造で画像認識にて高い精度を発揮する。リカレントニューラルネットワークは、時系列データを扱うために、中間層に別の層の時間を入力として接続する、回帰結合層を用いる手法である。音声や自然言語等の処理に用いられる。敵対的生成ネットワークは、生成器(Generator)と分類器(Discriminator)を用意し、生成器が偽サンプルを出力し、分類器が偽物かどうかを見分ける。複数の人物写真から、実在しない人物の高画質画像を生成するなど、画像生成での活用が進んでいる。

[2] 畳み込みニューラルネットワークの仕組み

ここでは、本研究で用いる畳み込みニューラルネットワークによる画像認識について説明する。Figure 10 に畳み込みニューラルネットワークの処理フローを示す。ここでは入力画像を 6×6 の行列として、入力層(Input)を構成する。次に畳み込み層(Convolution)により、入力画像に対してフィルタまたはカーネルと呼ばれる 3×3 の行列を掛け、画像から特徴を抽出する。フィルタは複数種類用意され、図中では 20 種類のフィルタにより 4×4 の行列が 20 組出力される。続く活性化層(ReLU)では、入力値が 0 以下の場合は 0 を、0 より大きい場合は入力値をそのまま出力する活性化関数による演算を行う。次の最大プーリング層(MaxPooling)では、 2×2 等で区切った小行列の中の最大値を求め、小行列を 1×1 に縮小した上でその最大値を格納する。結果、 2×2 の行列が 20 組出力される。フラット層(Flat)では各画像のセル値を縦一列に並べ、機械学習の入力とする。このように、入力画像から自動的に機械学習の特徴量を設定することで、入力データに人間が加工をすることなく、学習を行うことが可能となる。

以降は通常の機械学習の手順で出力データを得ることになるが、深層学習はネットワーク規模が複雑であり、モデルの自由度が高い。そのため教師データに対して過度にモデルがフィットしてしまい、学習範囲外のデータに対するロバスト性が低下する、過学習という現象が課題となる。そこで、ドロップアウト層(Dropout)を設け、フラット層からの入力信号を一定割合(30%等)、ランダムで遮断する操作を行う。すると、モデルの教師データへの依存性が下がり、よりロバストな結果を得ることが可能となる。最後に、全結合層で出力すべきパラメータにノードを絞り込む。




Figure 10 Data processing flow of the Convolutional Neural Network

畳み込み層、活性化層、最大プーリング層についての計算を具体的に説明する。 **Figure 11** に畳み込み層における計算イメージを示す。 6×6 の入力画像に対し、 3×3 のフィルタ 1 を入力画像の左上からスライドさせながら、重なった部分の数値を行列演算する。フィルタは複数用意(例: 1~20)され、フィルタ内の成分によって、画像からフィルタ枚に異なる特徴が抽出されるようにする。スライド幅はストライドと呼ばれ、本研究では 1 とする。フィルタが入力画像の中をスライドすることで、縦横それぞれ 4 枚、合計 16 枚のフィルタ出力が得られ、それを 4×4 の行列に格納して出力とする。

Convolution




Figure 11 Calculation image of Convolution layer

Figure 12 に活性化層と最大プーリング層における計算イメージを示す。活性化層は、入力値が 0 以下の場合には 0 を、0 より大きい場合は入力値をそのまま出力する。これは、ディープニューラルネットワークでは、通常のシグモイド関数による活性化では層が深くなるにつれて勾配が消えてしまう勾配消失問題があるためである。活性化層は 0 を起点にランプ応答を示すため、ゼロ近傍の入力値に対しても微分係数が低下することを防ぐことができる。また、最大プーリング層では、入力行列を 2×2 のプールサイズで区切り、区切った範囲内の最大値を求める。画像に対する効果としては、画像中のエッジを強調し、解像度を下げる操作に相当する。実際は入力画像のサイズは少なくとも 100×100 程度の大きさを有すると考えられるので、畳み込み層、活性化層、最大プーリング層を何回か繰り返して入力画像から特徴量を抽出していく。




Figure 12 Calculation images of ReLU and MaxPooling

2.2.4 本研究における機械学習の適用方針

前半で説明したデータ同化は、観測データと数値モデルの情報を融合により最適な推定値を求める手法であり、フィルタリング操作に際して、観測データと推定値の関係を記述する観測方程式が必要である。推定対象のシステムに対して支配方程式を記述し、物理モデル化することが可能なケースであれば、数値解析により観測演算子 $\mathbf{h}_t$ を得ることができる。本研究ではこれを、演繹的推定手法と呼んできた。しかし、所定の環境条件に対して確率的に発生する現象や、シミュレーションで再現できないばらつき因子が含まれ、観測データの定量的再現が難しい事象の場合は、数値解析結果の同化による推定精度向上が困難となる。

本研究ではこのような演繹的推定手法の活用が難しいシステムに対して、機械学習を用いた帰納的推定手法を適用する。実データを用いて機械学習モデルを構築し、システムの応答から内部状態を推定する。機械学習を用いて演繹的手法の推定精度を改善する取り組みとして、森らはトンネル工事時の未施工区間の岩盤特性の推定を行っている⁴⁴。本研究は自動車エンジンを対象とし、機械学習による観測モデルの構築を検討する。

2.3 海洋鋼構造物の防食状態モニタリング技術

2.3.1 金属腐食の発生メカニズムと代表的な防食方法

金属腐食とは、金属表面原子がイオンとなり海中に溶け出す現象である。海水のような溶存酸素を含む中性水溶液中に鉄が単独で存在する場合、アノード反応式(63)により、鉄が溶解する。



このとき溶存酸素が酸化剤となり、式(64)のようなカソード反応がおこる。



式(63)(64)は対になって反応は進行し、両式の反応速度が釣り合う電位を自然電位(または腐食電位)と呼ぶ。なお本論文では解析上、金属に対する水溶液の電位を正の方向とするが、腐食分野における基準と逆になるため、電位を比較する際は、電位の絶対値がゼロに近い方を貴、遠い方を卑と表記する。金属の電位は貴になるほど腐食しやすい。

次に電気防食(カソード防食)法について述べる。電気防食にはアノード防食とカソード防食の2種類があるが、前者は特殊環境でのみ使用される方法であるため、本論文では後者を電気防食と称する。電気防食は、海水中に設置される鋼材の最も一般的な防食法で、異種金属接触腐食現象を利用した方法である。異種金属接触腐食とは、電氣的に導通した状態の2種類の金属を海水中に設置した際、海水中における金属の自然電位が材料ごとに異なることに起因して、金属が1種類単独で存在する場合よりも腐食が促進、または抑制される現象である。海水中にアルミニウムと鉄を置いた場合を考えると、アルミニウムの方が自然電位が卑であるため、アルミニウムがアノード、鉄がカソードとなり、式(65)で示される反応により、アルミニウムは溶解する。



この時のアノード電流の大きさを $I_{\text{Al-Fe}}$ とし、アルミニウム、鉄を単独で海水中に置いた時の、それぞれの自身の酸化反応に伴うアノード電流の大きさを I_{Al} 、 I_{Fe} とすると、アルミニウム側から流れ出る電流の大きさは $(I_{\text{Al}} + I_{\text{Al-Fe}})$ となり、アルミニウムが単独で存在する時よりも腐食速度が増大する。一方、鉄側から流れ出る電流は $(I_{\text{Fe}} - I_{\text{Al-Fe}})$ となり、鉄が単独の場合に比べて腐食が抑制される。カソード防食はこの腐食抑制現象を利用した防食方法で、溶液中で防食対象にカソード電流を流し、防食対象のアノード反応を抑制することで腐食を防ぐ方法である⁴⁵。電位の観点から考えると、防食対象への電流の流入出がゼロになる電位を防食電位(0.78V)と呼び、鉄の表面近傍電位を防食電位よりも卑に保つことにより、防食が達成される。なお、実際には安全を見て、防食管理電位(0.80V)より電位が卑となるように防食設計が行われる。防食対象への電流の流し方は、アルミニウム-鉄の例のように、防食対象よりも自然電位が卑であるアルミニウムや亜鉛といった金属合金を犠牲陽極として取り付ける流電陽極方式と、外部に電源を用意し、強制的に電流を流す外部電源方式の2種類がある。大型海洋鋼構造物では、電源の設置

が不要で犠牲陽極の設置のみでよい流電陽極方式が用いられている。

最後に、被覆防食について述べる。被覆防食は空気中では最も一般的な防食方法であり、塗料や耐腐食金属で防食対象の表面を被覆することにより、水や酸素といった腐食因子の侵入を防ぐ方法である。海洋環境では、船舶の外板やバラストタンク内面、そして海洋鋼構造物の空気に触れる部位に、電気防食と併せて用いられる。

鋼構造物の一つであるジャケット式栈橋では、骨組みとなる鋼材に対して 2 種類の防食が行われている。空気と海水両方に触れる飛沫帯および干満帯には耐海水性ステンレス鋼ライニングなどの被覆防食が施されており、また、海中の鋼材に対しては流電陽極方式による電気防食が行われている⁴⁶。犠牲陽極はその性質上時間とともに消耗し、発生する電流量は減少する。そのため、発生電流量の測定による犠牲陽極の寿命評価が必要となる。現在の検査方法として、構造物周囲の電位測定による防食状態の簡易検査と、ダイバーによる犠牲陽極の詳細検査が行われている⁴⁷。しかし、判定結果の信頼性や定量性、さらに大型な構造物においては、時間や労力のコスト増が問題となる。重要な社会インフラとして今後も増加が予想される港湾施設や海上構造物を維持管理していく上では、数値解析を援用して海洋鋼構造物の防食状態を経済的かつ効率的に推定する手法の確立が望まれる。

2.3.2 腐食防食のシミュレーション技術

腐食防食解析の歴史は 60 年以上前にさかのぼる。Waber らは 1956 年にアノードとカソードの分極特性を直線とした場合についての電位分布を解析的に算出した⁴⁸。電気防食下における電位分布は、領域においてイオンの損失や増加が生じないと仮定した上で、ラプラス方程式(66)で表される。 ϕ は領域内の電位、 κ は電解液の電気伝導度である。

$$\nabla \cdot (\kappa \nabla \phi) \quad (66)$$

一般の境界値問題では、基本境界条件(67)および自然境界条件(68)が与えられる。 i_n は境界における法線方向の電流密度である。

$$\phi(x_0, y_0) = \phi_0 \quad (67)$$

$$\kappa \frac{d\phi}{dn} + i_n = 0 \quad (68)$$

ここで、 i_n は金属表面での分極に起因して値が変化するため、定数ではなく分極特性式(69)を与える必要がある。コンピュータの援用無しでは、実際の分極特性の非線形性や任意形状の計算が困難であった。

$$i_n = f(\phi) \quad (69)$$

計算機性能が発達した 1980 年代頃から、数値計算を用いた腐食防食シミュレーションに関する研究が活発化し、ミクロな腐食現象の解析や、船舶や海洋構造物を対象とした電位予測結果が報告されている。Helle らは有限要素法(Finite Element Method, FEM)を用いて電位分布の数値解を得る方法を示した⁴⁹。

ここでは分極特性を考慮するために、電極表面上の節点の電位に仮定した値を与えて FEM 計算を行い、計算の結果得られた電位が、予め仮定した電位と一致するよう収束計算を行っており、計算負荷の増大が課題であった。永井らは、分極特性を線形近似することで収束計算を不要として計算を高速化し、2 次元形状⁵⁰および 3 次元形状⁵¹での計算結果の妥当性を示した。

岩田らは、防食設計に必要な境界部のみを解析することで計算負荷を軽減可能な境界要素法(Boundary Element Method, BEM)を用いて、電位分布を計算するシミュレーションを提案した⁵²。

Cicognani らは海洋構造物を模擬した 3 次元形状で電位推定精度 5~50%程度の結果が得られることを示した⁵³。Yan らは 2 次元ラプラス方程式に基づく BEM モデルにより、鉄板上に犠牲陽極を配置した試験セル周囲の電位分布を推定可能であることを示した⁵⁴。Fratesi らは BEM モデルにより石灰質被膜の形成による電流低下の解析を可能とした⁵⁵。

2000 年代に入ると、腐食防食シミュレーションを実製品の防食設計へ適用する検討が本格化した。田代らは有限要素法を橋脚基礎や鋼管矢板基礎の防食設計にて適用した例を示した⁵⁶。DeGiorgi らは船舶のスクリューの電気防食の BEM 解析における、スクリュー形状の詳細度と精度の関係を解析した⁵⁷。Montoya らは鉄筋コンクリートにおける電気防食を FEM で解析し、コンクリート部の電気伝導度と鉄筋の腐食の関係を明らかにした⁵⁸。Guibert らは FEM を用いて船舶の周辺電位から、船舶表面電位を逆解析で推定する手法を提案した⁵⁹。Ridha らは海水中ポンプの防食設計を BEM 解析を用いて行えることを示した⁶⁰。Lan らは、BEM を用いて海上プラットフォームの腐食解析を行い、実験値との良好な一致を確認した⁶¹。しかし、これらの防食解析では犠牲陽極や構造物表面の境界条件を既知として与えた上で、周辺の電位や電流を計算しており、境界条件が未知の場合の防食解析を行うには至っていない。

筆者らのグループは、数値解析を用いて犠牲陽極の電流量を推定する逆解析手法の提案を行ってきた。逆解析とは、周辺の電位測定値より未知の境界条件を推定する手法である。滝本らは一つの犠牲陽極周囲の電位測定から、その犠牲陽極の電流量を同定する手法を開発した⁶²。また大野らは構造物周辺の電位測定値から複数の犠牲陽極発生電流量を同時に同定する手法の基礎的検討を行い、犠牲陽極と鋼材をモデル化したジャケット構造物の有限要素法モデルを用いた数値実験により、その有効性を示した⁶³。

実環境での適用に向けては、様々な海洋環境の影響を考慮した適切なシミュレーションモデル化や、電位測定誤差を考慮した逆解析手法の構築が求められる。また、現在の防食状態の高精度モニタリング技術は、防食状態の将来予測にも適用可能であると考えられ、過去データを蓄積、活用する手段の具体化が望まれている。

2.4 エンジン状態モニタリング技術

2.4.1 エンジンの燃焼状態モニタリング技術

LCA 観点での CO₂ 排出量低減の観点から、自動車には多様なパワートレインの活用が有効であると考えられている⁶⁴。ガソリンエンジンにおいても、ハイブリッド車技術や再生可能エネルギー由来の燃料のポテンシャルを最大限に引き出すために、継続的な熱効率の向上や排気の低減が求められる。

エンジンの熱効率を向上させるための主要施策として、ピーク熱効率の向上、低負荷などの熱効率の低い領域のカバー、そして高負荷ノックの抑制が考えられる。第一にピーク熱効率の向上について、Luszcz らは空気過剰率 $\lambda=1.9$ の超リーンバーンにより図示熱効率 46%を実証した⁶⁵。Zhang らはコロナ点火シ

システムのポテンシャルについて検討し、図示熱効率 49.5%を達成した⁶⁶。Osborne らはリーン燃焼と排気後処理システムの組み合わせにより、欧州排気規制 Euro6d に適合し、かつ CO₂ 排出量を 15%低減できることを示した⁶⁷。第二に、低負荷領域などの低熱効率領域については、ハイブリッド車のモータによる駆動を行うことで、エンジンの運転を回避する方策が取られる。近年の電動車販売シェアの高まりを受け、ハイブリッド車向けエンジン技術が数多く研究されている。濱谷らはエンジンと電動モータを協調させて車両を駆動するパラレルハイブリッド方式を提案している⁶⁸。鶴島らはエンジンを車輪と接続せず発電専用として用いるシリーズハイブリッド方式を提案した⁶⁹。江川らはクラッチを用いて、エンジンを発電専用モードと車軸駆動モードを運転条件により使い分ける方式を開発した⁷⁰。三番目に高負荷時のノッキング抑制がある。ガソリンエンジンの高負荷時の熱効率は依然、ノッキングにより律速されており、ノック抑制技術への関心は高い。Scharf らは 200kW/L の出力クラスのエンジンにおいて、全領域において燃料増量を必要としない空気過剰率(Air Excess ratio, λ)1.0 での運転を可能とする燃焼コンセプトを開発した⁷¹。Kapus らはミラーサイクル、排気再循環(Exhaust Gas Recirculation, EGR)、および可変容量ターボを用いて 80-90kW/L 出力クラスのエンジンにて全領域 $\lambda=1.0$ 運転を達成する見通しを発表した⁷²。Glahn らは全領域 $\lambda=1.0$ 達成に必要な技術をまとめ、90kW/L 以上の出力クラスでは、水噴射などの追加デバイスが必要になるとの見解を示した⁷³。

上記のような燃焼改善技術を適用した上で、エンジンは燃費排気低減ポテンシャルを最大限に活用するために、燃焼不安定化や失火、ノッキング限界などの燃焼限界に近い領域での運転が求められる。燃焼状態の検知に誤差がある場合、燃焼安定側に制御マージンを取る必要があり、燃費や排気が悪化してしまう。そのため、次世代エンジンにおいても燃焼状態の高精度モニタリングがキー技術の 1 つになると考えられる。また、エンジン車のリアルワールドにおける排気低減に対する社会的関心が高まっており、欧州 Euro7 に代表される次期排気規制では、車両のライフタイムとして 10 年間の性能保証が規制化される見通しである⁷⁴。車両劣化等に起因する燃焼不安定や失火を、高精度に検出する必要がある。

エンジンの燃焼状態検出手段は、筒内圧センサーによる燃焼圧力の測定が最も直接的である。筒内圧測定は 1980 年代から研究されており、川村らは気筒別の圧力検出により燃焼位相を制御可能なことを示した⁷⁵。竹内らはピエゾ抵抗効果を用いた筒内圧センサーを開発し、量産化を可能とした⁷⁶。島崎らは、筒内圧センサーを点火プラグに一体化させ、搭載性を改善した⁷⁷。Toth らはシリンダヘッドのガスケットと一体化させて装着可能な筒内圧センサーを開発した⁷⁸。Romani らは点火プラグにひずみワッシャを装着し、点火プラグが燃焼室から受ける圧力をひずみとして検出する筒内圧センサーを開発した⁷⁹。近年は、エンジンのポテンシャルを最大限に引き出すための手段として筒内圧センサーへの関心が高まっている。中井らは、火花点火制御圧縮着火(Spark Controlled Compression Ignition, SPCCI) の燃焼制御のため、全気筒に筒内圧センサーを搭載した SKYACTIV-X エンジンを発表した⁸⁰。しかし、量産エンジンに筒内圧センサーを追加で搭載する場合、車両コストが増加する点が依然課題となっており、大衆車への採用には至っていない。

エンジンに既に搭載されているセンサーを用いた燃焼検出手段としては、A/F センサー、ノックセンサー、クランク角センサー、点火コイルが挙げられる。A/F センサーは排気管に備えられ、排気ガス中の O₂ 濃度を計測可能である。Pauer らは、O₂ 濃度の実測値と物理モデルに基づき、排気管下流の触媒に流入する排気の O₂ 濃度を推定し、フィードバック制御を実施している⁸¹。しかし、燃焼室による燃焼発生から、A/F センサーによる O₂ 濃度には時間遅れがあり、サイクル毎の燃焼状態の評価は困難である。また、

センサーは車両に排気管集合部に 1 つしか搭載されないため、気筒別の燃焼状態の検出も困難となる。

ノックセンサーは、異常燃焼であるノッキング発生時のエンジンプロック振動を検出する加速度センサーである。Rugland らは、ノックセンサー信号と吸気温度、吸気圧、A/F および燃料噴射量の情報を基に、物理モデルで筒内圧を予測する手法を提案した⁸²。Posch らは、運動方程式に基づいた伝達関数でノックセンサー信号をモデル化し、実測値を用いてパラメータを適合することで、燃焼圧ピーク値を高精度に予測できることを示した⁸³。しかし、エンジン振動は間接的な情報であり、運転領域違いやエンジン違いに対してロバストに燃焼特性を予測することが困難である。

クランク角センサーは、クランク軸端に取り付けられた回転数センサーである。膨張行程におけるエンジン燃焼によるクランク軸の加速を検出することで、失火の検出や、燃焼トルク、および燃焼圧を推定する技術が提案されている。Liu らは、クランク角センサー信号から求めた回転数の二乗の差分から燃焼トルクを推定する方法を提案した⁸⁴。青野らは、クランク角センサー信号をフーリエ級数展開を用いたフィルタリングによる、軽計算負荷な燃焼トルク推定手法を提案した⁸⁵。Kulah らは、トラック用ディーゼルエンジンを用いて、クランク角センサーから燃焼位相をリアルタイムに推定可能なことを示した⁸⁶。米谷らは、クランク角センサーの歯間隔の製造誤差に起因するピッチエラーを学習し、補正する手法を提案した⁸⁷。しかし、検出される回転数は、クランク軸やトランスミッション側の慣性トルクの影響を受けており、燃焼トルクの寄与度が相対的に低い低負荷条件などでは、検出精度が低下する。また、高回転領域ではクランク軸自身のねじり振動によるノイズ増大も課題となる。さらに、気筒数が多い場合も、各気筒の圧縮行程、膨張行程で発生するトルクの影響が重複し、検出精度が低下してしまう。

点火コイルは、点火プラグ電極間に放電によるスパークを発生させ、混合気の燃焼を開始させるデバイスである。点火コイルを活用した燃焼状態検出手法としては、燃焼によって発生するイオンを検出する、イオン電流センシングが実用化されている。Cavina らは、イオン電流に基づいて、V8 および V12 エンジンにおけるオンボード失火検出性能を実証した⁸⁸。土井らは、イオン検出精度向上に向けた点火プラグ形状の改善を行った⁸⁹。Shah らは、副室を搭載した天然ガスエンジンにおけるイオン電流挙動を測定し、副室燃焼におけるイオン電流センシング課題を明らかにした⁹⁰。緒方らは、イオン電流センシングを予混合圧縮着火(Homogeneous Compression Charge Ignition, HCCI)制御に適用する際のイオン検出用電圧の要求値を定量化した⁹¹。楠原らは、イオン電流を用いた EGR 率フィードバック制御により、燃焼変動を抑制できることを実証した⁹²。熊野らは、イオン電流に基づくノッキング検出の高精度化のため、規格化したイオン電流信号変化を特徴量としたデータ処理手法を提案した⁹³。Angeby は、イオン電流センシングに適した点火コイル方式を検討し、放電終了直後のリングングノイズの短い容量方式が望ましいことを示した⁹⁴。しかし、イオン電流センシングにて発生するイオンの出力強度は、燃焼温度と相関があり、リーンや EGR 条件では出力強度が低下する。イオン強度が検出限界以下になる、または燃焼条件によりフィードバック制御の閾値を変える必要がある点が課題となり、採用は一部車種にとどまっている。

一方で、点火コイルから発生する電圧電流を用いた燃焼検出手段も検討されている。点火コイルにより形成される放電路は、筒内流速や温度、圧力や点火プラグ電極ギャップ距離等によってその状態が変化し、その挙動が電圧電流信号に現れる。白石らは、点火コイルの二次電流に基づいて放電期間を検出し、点火プラグのギャップ長を推定する手法を提案した⁹⁵。志方らは、点火コイルの二次電流から放電期間を検出し、タンブル流速及び燃焼安定性を推定している⁹⁶。船戸らは、吸気行程または排気行程中に複数回の微小放電を行い放電成功率に基づいて点火プラグの摩耗状態を推定する手法を提案した⁹⁷。しかし、放

電路は流動ばらつきや点火プラグ表面状態などの影響を強く受け、放電路伸長や放電路再形成(リストライク)の挙動はサイクル毎に大きく変動する。その結果、電圧電流応答には流速、温度、圧力、電極表面抵抗の影響が複合的に表れ、単一特徴量の抽出および閾値判定処理では、サイクル毎の燃焼状態を精度良く検出することが困難であった。そのため、点火コイル電圧電流に基づく燃焼診断は、サイクル平均データに基づく平均的な挙動評価や、ハードウェアの劣化診断にとどまっている。

上記のような複数の物理現象が入り混じったデータの処理手段として、機械学習を用いたデータ駆動アプローチが、近年盛んに研究されている。Bellone らは、CNN を用いてエンジンコントロールユニット(Engine Control Unit, ECU)のモニタ値より燃料流量や排気を予測するモデルを構築した⁹⁸。Hanuschkin らは、燃焼室内における燃焼開始時の火炎核をレーザーを用いて撮影し、画像処理により抽出した特徴量を入力として筒内圧ピーク値を予測するモデルを構築した⁹⁹。

これらの文献は信号生データ、または手動で定義した特徴量を機械学習の入力としているが、パラメータの選定や特徴量定義方法の一般化が難しいという課題がある。そこで、エンジンからの情報を画像ベースで取り込み CNN に画像認識させて、特徴量を定義することなく燃焼特性を予測する研究がなされている。Johnson らは燃焼室内の火炎伝播を高速カメラで撮影し、深層学習を用いて画像認識させることで燃焼位相の予測を行った¹⁰⁰。Warey らは、数値流体力学(Computational Fluid Dynamics, CFD)シミュレーションにより燃焼室内の当量比、温度、流速、乱流運動エネルギー(Turbulent Kinetic Energy, TKE)を 2 次元平面コンター画像に出力し、深層学習を用いて画像認識させることで、CFD による排気成分解析結果を高精度に予測できることを示した¹⁰¹。機械学習学習、特に CNN を用いた解析技術の研究が進んでいるが、点火コイル信号を対象とした燃焼診断を検討した論文は少ない。そこで、本論文の第 5 章では、深層学習の画像認識を用いて、点火コイルの電圧電流信号からサイクル毎の失火検出をすることを検討する。

2.4.2 燃料混合率のモニタリング技術

エンジンの燃焼状態モニタリング技術に際してもう 1 つ課題となるのが、使用する燃料の不確実性である。現在、自動車に用いられる液体燃料は主にガソリンとディーゼル(軽油)がある。着火性や蒸発特性を決める主要成分が規定以内に収まるよう規格化、管理されているが、季節ごとに添加剤の影響などで燃料成分は変動する。また PHEV の場合は外部給電した電気による EV モード走行を多用した場合、給油頻度が減り、燃料が車両タンク内に半年以上の長期に渡り保管されることが想定される¹⁰²。

また自動車分野の脱炭素化に向けて、風力などの再生可能エネルギー由来の電力と CO₂ を用いて化学的に合成される燃料 (e-Fuel) の検討が欧州を中心に進められている。e-Fuel は化石燃料に由来しないため、適切な再生可能エネルギーと CO₂ 源を確保できれば、CO₂ および有害排気物質の大幅な排出抑制が可能である。特に液体状態の e-Fuel は既存のインフラで内燃機関車に給油して使用でき、市場の大半を占める既存車の CO₂ 低減が図れるため、電動車の販売増加による CO₂ 低減を補完する技術として有望視されている。ディーゼル車向け e-Fuel は OME (Oxyethylene Ethers) の検討がドイツの公的資金プロジェクトで実施¹⁰³されており、Gaukel らにより OME の低排気特性がエンジン試験で確認されている¹⁰⁴。ガソリン向け e-Fuel は、DMC(Dimethyl carbonate)¹⁰⁵や MeFo(Methyl formate)¹⁰⁶、Cyclopentanone 等複数成分の混合 e-Fuel¹⁰⁷等を対象として、燃焼性能の評価が大学や自動車メーカー、サプライヤー等に

より積極的に進められている。

e-Fuel の具体的な成分は、生産性や地域性を考慮して政府主導で決定されることが考えられるが、既に普及しているエタノール等のバイオ燃料と同じく、高オクタン価、低揮発性を持つことが予想され、燃料違いによる燃焼特性への影響大きい。また、導入初期は既存の化石燃料との混合燃料としての使用が想定されるため、燃料混合率に応じたエンジン制御が求められる。

ここで、既存の燃料性状検知技術について説明する。エタノールやメタノールに代表されるバイオ燃料は、さとうきび等のバイオマス資源から生成することができ、欧州や米国をはじめ、多くの国で化石燃料との混合燃料の形で使用されている¹⁰⁸。ブラジルでは 2003 年からエタノールの自動車エンジンへの適用が始まっており、フレックス燃料車(Flex Fuel Vehicle, FFV)はエタノール混合率 0%~100%に対応するためのアルコールセンサーが搭載されている¹⁰⁹。また、アルコールセンサーを補完する技術として、Oliverio らは筒内圧¹¹⁰、Ahn らは A/F センサー¹¹¹によるエタノール混合率推定を提案している。しかし、これらの技術はガソリンとエタノール 2 種類の混合を前提とした推定アルゴリズムとなっており、e-Fuel が加わり 3 種類以上の混合の際には混合率の推定が困難となる。多種燃料が長期保存される将来エンジンには、外界情報や車両からの情報を包括的に取り込み、燃料の劣化および混合による特性変化を、継続的にモニタリングする仕組みが必要と考えられる。

第3章 ベイズ推定を用いた海洋鋼構造物の犠牲陽極発生電流量同定法の開発

3.1 はじめに

本章では、実際の鋼構造物周辺の電位測定値から、犠牲陽極の電流量および構造物表面電位を推定する逆解析手法を開発する。具体的には、逆解析を実環境に適用できる解析モデルの構築や、海洋環境と測定に起因する解析パラメータの不確定性を考慮した観測方程式の構築、ベイズ推定による逆問題の適切化、そして実際のジャケット構造物における検証実験を行う。数値計算には、ジャケットのような複雑な形状のモデル化や、解析領域中の電気伝導率が不均一な場合でも解析が可能な有限要素法を用いた。

3.2 逆解析手法

3.2.1 解析概要

本手法は、ジャケット式栈橋構造物周辺の電位分布を測定し、その測定データから犠牲陽極発生電流量を逆解析により推定するものである。逆解析の流れを **Figure 13** に示す。構造物形状情報などから有限要素法モデルを作成し、犠牲陽極からの電流量をある値に仮定した際の、電位応答を計算する。そして、電位の測定値と計算値が合うように電流量を調節し、最も測定値と計算値が合う際の電流量を推定値とする。しかし複雑な形状をした鋼構造物においては、周辺における電位測定値に対して、各境界からの電流量を一意に定めることが困難である。そこでベイズ推定法を用いて、現場の測定値と事前に蓄積された技術的知見を組み合わせることにより、推定精度を向上させる。次節より、各ステップについて詳細に述べる。




Figure 13 Flow of the inverse analysis

3.2.2 電位測定

電位測定時の機材配置を **Figure 14** の右側に示す。まず、船または付近の足場などを利用して構造物に近寄り、アース電極を構造物に取り付ける。ステンレス鋼と下部の鋼材は導通しているので、本測定においては、アース電極がグラウンドとなる。次に、海中に2種類の参照電極(海水銀/塩化銀電極)を投入する。1つ目は移動参照電極(以下、移動電極と呼ぶ)で、水深測定用の圧力センサーと複合させたものを用いる。2つ目は固定参照電極(以下、固定電極と呼ぶ)で、海中の鋼材付近に投下し、位置は固定す

る。電位測定値とは、移動電極・グラウンド間の電位差を指すが、電位差の時間変化による誤差を減少させるために、固定電極を併用する。移動電極・グラウンド間の電位差を $\phi'_{\text{move-gnd}}$ 、固定電極・グラウンド間の電位差を $\phi'_{\text{fix-gnd}}$ 、移動電極・固定電極間の電位差を $\phi'_{\text{move-fix}}$ とすると、3者の関係は以下の式(70)ようになる。

$$\phi'_{\text{move-gnd}} = \phi'_{\text{move-fix}} + \phi'_{\text{fix-gnd}} \quad (70)$$

右辺二項のうち、 $\phi'_{\text{move-fix}}$ は比較的安定するが、 $\phi'_{\text{fix-gnd}}$ は温度、波浪など、周辺環境の時間変化による変動が大きい。そこで $\phi'_{\text{move-fix}}$ は各測定点における値をそのまま用い、 $\phi'_{\text{fix-gnd}}$ は時間平均値を用いることで、 $\phi'_{\text{fix-gnd}}$ の時間変動の影響を軽減することができる。3種類の電位差および圧力センサーによる水深をデータロガー、PCに記録する。また、並行して電気伝導度計を投入し、海中の深度方向の電気伝導率を測定する。有限要素法計算では電気伝導率の場所による不均一性を考慮した計算が出来るので、ここで測定した値を入力値に用いる。




Figure 14 Measurement settings and boundary conditions of a jacket structure in the cathodic protection

3.2.3 数値計算

構造物形状情報、海中および土中の電気伝導率、そしてカソードの分極曲線を線形近似したデータを用いて、数値計算により構造物周辺の電位計算を行う。電気防食に関連する数値計算では、従来より境界要素法が広く用いられているが、有限要素法では、解析領域中における電気伝導率の不均一性を考慮した解析が可能である。Bertoliniらは海水中およびコンクリート中の防食電流の解析のため、電気伝導率が異なる領域での解析を行った¹¹²。Parsaらは、石油パイプラインの防食解析において、土の状態に応じて電気伝導度を領域ごとに切り替えた計算を行っている¹¹³。港湾施設においては、河川水と海水の混合状態に依存して、電気伝導率が不均一な値を取る場合がある。そのため本研究では、電気伝導率の不均一性を考慮した解析が可能な有限要素法を用いた。

Figure 14左側に境界条件設定を示す．解析領域として，構造物周辺の海水および海底土で満たされた領域 Ω を考える．領域の境界は，犠牲陽極表面のアノードとなる境界 Γ_a ，骨組の鋼材で，カソードとなる境界 Γ_{c1} ， Γ_{c2} (それぞれ海中，土中の鋼材を表す)，海面付近の耐海水性ステンレス鋼でカソードとなる境界 Γ_{c3} ，海水を仮想的に分割した海中領域の鉛直面境界(以下，海中壁と呼ぶ) Γ_{sea} ，海中領域の上部の境界 Γ_{air} ，そして海底土を仮想的に分割した土中領域の境界 Γ_{soil} で囲まれる．領域内の電位を ϕ ，電気伝導率を κ ，そして境界における法線方向の電流密度を i とする．領域においてイオンの損失や増加が生じないとし，海中と土中の電気伝導率が不均一である点を考慮すると，領域内の電位 ϕ は支配方程式として式(71)を満足する．また境界上の電流密度は式(72)で表される． $\partial/\partial n$ は外向き法線方向微分を表す．なお本稿では解析上，電位 ϕ は金属に対する海水の電位を考えているため，通常電気化学で用いる，溶液に対する金属の電位の符号を逆転させている．

$$\nabla \cdot (\kappa \nabla \phi) \quad (71)$$

$$i \equiv \kappa \frac{d\phi}{dn} \quad (72)$$

ここで境界条件は，未知パラメータを含んだ形でそれぞれ式(73)・(78)で与える．(71)を数値解析で解くことにより，領域内の電位および境界上の電流密度を計算する．

$$\phi = -R_S i + \phi_S, \quad \text{on } \Gamma_{c1} \quad (73)$$

$$i = f_1(I_{anode}), \quad \text{on } \Gamma_a \quad (74)$$

$$i = f_2(I_{steel-soil}), \quad \text{on } \Gamma_{c2} \quad (75)$$

$$i = f_1(I_{sus}), \quad \text{on } \Gamma_{c3} \quad (76)$$

$$i = f_1(I_{sea}), \quad \text{on } \Gamma_{sea} \quad (77)$$

$$i = 0, \quad \text{on } \Gamma_{air} \text{ and } \Gamma_{soil} \quad (78)$$

Γ_{c1} では式(73)の通り，金属境界条件として鋼材の分極曲線を線形近似したものを用いる． R_S は分極曲線の傾きで，金属の分極抵抗を表す． ϕ_S は分極曲線の切片である(以下，切片電位と称する)．切片電位は，海中鋼材への電流量がゼロとなる場合の鋼材表面の電位を表す解析上の仮のパラメータであり，実構造物で上記の現象が起きたと仮定した場合に，海水銀塩化銀電極により電位を測定した値と一致する． Γ_{c1} では上記2つのパラメータを未知数として同定する．通常，空气中に鋼材が露出する構造物であれば，腐食が海中に比べて厳しい干満帯の影響^{114, 115}を考慮する必要があるが，本研究の対象となる構造物の干満帯にはステンレス鋼被覆が施されており，別の境界 Γ_{c3} を与えている．また溶存酸素量などの腐食環境が海中と異なる土中鋼材には境界 Γ_{c2} を与えている．それぞれ海中鋼材とは異なる境界条件を与えて，干満帯および土中鋼材の影響を考慮するため，ここでは海中部の鋼材分極抵抗は一樣と仮定する．なお分極曲線については，本研究における検査対象では，測定される電位の最大値と最小値の差が100 mV以内であるので，石灰質被膜付着を模擬した鋼材試験片から継続的に取得した分極曲線を，現場で測定された電位域で線形近似して，その傾き R_S の確率分布をベイズ推定の事前情報に用いる． Γ_a ， Γ_{c2} ， Γ_{c3} には式(74)・(76)の通り，電流密度指定の境界条件を与える．本来，金属表面は式(73)のような金属境界条件を与えるべきであるが，犠牲陽極には消耗や腐食生成物の付着，土中鋼材には土中の電気

伝導率や鋼材分極抵抗の変化，そしてステンレス鋼には浸漬率や石灰質被膜，不動態皮膜形成が起こるため，分極曲線を正確に求めることが困難である．そこで，これらの境界条件には電流量で定まる一様電流密度 f_1 を指定し，未知数として電流量を同定する．実環境においては金属表面の電流密度は一様とはならないが，犠牲陽極の表面領域 Γ_a はジャケット栈橋のカソード領域 Γ_{c1} と比べ十分小さいこと，また鉛直方向に電位測定を行うため，ステンレス鋼領域 Γ_{c3} の電流密度分布が測定データに与える影響が小さいことから，電流密度を一様と仮定して，それぞれからの電流量 I_{anode} ， I_{sus} を未知数とする．式(75)には，土中鋼材表面の電流密度は深度により減少することから，深度とともに電流密度が低減するという，代表的な電流密度分布 f_2 を与える．そして土中鋼材へ流れ込む総電流量 $I_{steel-soil}$ を未知数とする．

Γ_{sea} には式(77)の通り，海中壁を通じで流入出する電流量 I_{sea} を未知数とした一様電流密度を境界条件として与える． Γ_{air} および Γ_{soil} は絶縁境界として扱う．すなわち，領域外への電流の流入出は海中壁 Γ_{sea} のみから起こると仮定する．海面は絶縁であり，また海底土は電気伝導率が低く，土中鋼材へ流れ込む電流は主に海中領域の犠牲陽極から供給されるため，両境界からの電流の流入出は無視できると考えられる．上記の境界条件で与えるパラメータには同定すべき未知数が含まれているため，有限要素法順計算で未知数を直接求めることはできない．そこで，各境界から単独で電流を1 A発生させた際の構造物付近の電位変化を計算し，それを各境界に対して行うことで，境界ごとの，単位発生電流量あたりの電位変化のデータベースを作成する．これは後述の観測行列 $A(R_S)$ となる．

3.2.4 ベイズ推定を用いた逆解析

[1] 観測方程式の構築

測定点における，誤差を含んだ測定値を ϕ' とする． ϕ' は m 個の測定値 $\phi'_1, \phi'_2, \dots, \phi'_m$ からなる列ベクトルである．また同定値である，4種類の境界からの発生電流量および切片電位からなる列ベクトルを $\mathbf{X}$ とする．ただし，各境界は必要に応じてさらにグループ分けされる．今回は例として，犠牲陽極を2グループに分けて式を導出する．他の境界についても同様のグループ分けが可能である．ここで ϕ' を，電位の真の値 ϕ ，測定誤差やモデル誤差などの誤差をまとめた ε の2つに分離する．領域内における電位は，式(71)を満足するため，測定値 ϕ' と同定値 $\mathbf{X}$ の間には，式(79)で表される観測方程式が成立する．

$$\phi' = A(R_S)\mathbf{X} + \varepsilon \quad (79)$$

$A(R_S)$ は R_S に依存する観測行列である． R_S に仮の値を与えて有限要素法計算を行い， $A(R_S)$ の各成分を求めることにより，観測方程式を構築する．以下， $A(R_S)$ の導出方法を述べる．式(79)の電位の真の値 ϕ に注目すると，

$$\phi = A(R_S)\mathbf{X} \quad (80)$$

となる．ここで構造物中の各境界のうち，1種類，例えばanode(1)境界のみが機能している場合の，電流量と測定点での電位変化は次式(81)を満足する．

$$\begin{pmatrix} \Delta\phi_1^{\text{anode}(1)} \\ \Delta\phi_2^{\text{anode}(1)} \\ \vdots \\ \Delta\phi_m^{\text{anode}(1)} \end{pmatrix} = A(R_S) \begin{pmatrix} I_{\text{anode}(1)} \\ 0 \\ \vdots \\ 0 \end{pmatrix} \quad (81)$$

各種境界の電流量および切片電位について式(81)と同様の式が成り立つので，それらの列ベクトルを横に並べると，式(82)のように表せる．

$$\begin{bmatrix} \Delta\phi_1^{\text{anode}(1)} & \Delta\phi_1^{\text{anode}(2)} & \Delta\phi_1^{\text{steel-soil}} & \Delta\phi_1^{\text{sus}} & \Delta\phi_1^{\text{sea}} & \phi_S \\ \Delta\phi_2^{\text{anode}(1)} & \Delta\phi_2^{\text{anode}(2)} & \Delta\phi_2^{\text{steel-soil}} & \Delta\phi_2^{\text{sus}} & \Delta\phi_2^{\text{sea}} & \phi_S \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \Delta\phi_m^{\text{anode}(1)} & \Delta\phi_m^{\text{anode}(2)} & \Delta\phi_m^{\text{steel-soil}} & \Delta\phi_m^{\text{sus}} & \Delta\phi_m^{\text{sea}} & \phi_S \end{bmatrix} = A(R_S) \begin{bmatrix} I_{\text{anode}(1)} & 0 & 0 & 0 & 0 & 0 \\ 0 & I_{\text{anode}(2)} & 0 & 0 & 0 & 0 \\ 0 & 0 & I_{\text{steel-soil}} & 0 & 0 & 0 \\ 0 & 0 & 0 & I_{\text{sus}} & 0 & 0 \\ 0 & 0 & 0 & 0 & I_{\text{sea}} & 0 \\ 0 & 0 & 0 & 0 & 0 & \phi_S \end{bmatrix} \quad (82)$$

よって $A(R_S)$ は式(83)となる．

$$A(R_S) = \begin{bmatrix} \frac{\Delta\phi_1^{\text{anode}(1)}}{I_{\text{anode}(1)}} & \frac{\Delta\phi_1^{\text{anode}(2)}}{I_{\text{anode}(2)}} & \frac{\Delta\phi_1^{\text{steel-soil}}}{I_{\text{steel-soil}}} & \frac{\Delta\phi_1^{\text{sus}}}{I_{\text{sus}}} & \frac{\Delta\phi_1^{\text{sea}}}{I_{\text{sea}}} & 1 \\ \frac{\Delta\phi_2^{\text{anode}(1)}}{I_{\text{anode}(1)}} & \frac{\Delta\phi_2^{\text{anode}(2)}}{I_{\text{anode}(2)}} & \frac{\Delta\phi_2^{\text{steel-soil}}}{I_{\text{steel-soil}}} & \frac{\Delta\phi_2^{\text{sus}}}{I_{\text{sus}}} & \frac{\Delta\phi_2^{\text{sea}}}{I_{\text{sea}}} & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{\Delta\phi_m^{\text{anode}(1)}}{I_{\text{anode}(1)}} & \frac{\Delta\phi_m^{\text{anode}(2)}}{I_{\text{anode}(2)}} & \frac{\Delta\phi_m^{\text{steel-soil}}}{I_{\text{steel-soil}}} & \frac{\Delta\phi_m^{\text{sus}}}{I_{\text{sus}}} & \frac{\Delta\phi_m^{\text{sea}}}{I_{\text{sea}}} & 1 \end{bmatrix} \quad (83)$$

$A(R_S)$ の各成分(切片電位の列を除く)は，“各境界の発生電流量1 Aあたりの構造物付近の各測定点における電位変化”を表し，有限要素法計算によりこれらの値を計算する．

[2] ベイズ推定による未知数の同定

構築した観測方程式により，電位の測定値 ϕ' から各境界の電流量および切片電位を同定する．その際ベイズ推定により，電位測定値の持つ誤差や，モデルのパラメータが持つ不確定性による，同定精度への影響の評価，そして技術的な知見による事前情報を利用した同定結果の補正を行う．不確定性をもつパラメータである電位の測定誤差や鋼材分極抵抗，各境界の電流値，切片電位の事前情報を事前分布として正規分布で表現する． R_S の事前分布 $p(R_S)$ を用いて R_S に仮定値を与え，推定尤度分布の平均値 $\hat{\mathbf{X}}(R_S)$ および分散共分散行列 $P(R_S)$ を式(84)，(85)に従い計算する．そして，それらの計算結果を R_S 仮定値の

出現確率に基づき加重平均を行う形で式(86)を計算することで，測定値 ϕ' を得たときの同定値 $\mathbf{X}$ の尤度分布 $\mathcal{L}(\mathbf{X}|\phi')$ を得る． $\mathbf{X}_0 = \mathbf{N}(\hat{\mathbf{X}}_0, P_0)$ は未知パラメータの事前情報， $\varepsilon = \mathbf{N}(\bar{\mathbf{w}}, W)$ は電位の測定誤差の事前分布を表す． $\mathbf{N}$ はガウス分布を表し，括弧内の成分はそれぞれ平均値，分散行列である． T は転置を表す．

$$\hat{\mathbf{X}}(R_S, \phi') = \hat{\mathbf{X}}_0 + P(R_S)A^T(R_S)W^{-1}\{\phi' - (A(R_S)\hat{\mathbf{X}}_0 + \bar{\mathbf{w}})\} \quad (84)$$

$$P(R_S) = (A^T(R_S)W^{-1}A(R_S) + P_0^{-1})^{-1} \quad (85)$$

$$\mathcal{L}(\mathbf{X}|\phi') = \int N(\hat{\mathbf{X}}(R_S, \phi'), P(R_S))p(R_S)dR_S \quad (86)$$

[3] 分極モデル推定による犠牲陽極個々の電流量評価

前節の同定結果は，犠牲陽極の電流量は各グループ内では同一と仮定して扱っているが，実際の犠牲陽極は取り付け位置などにより電流量にばらつきが出る．そこで電流量のばらつきを考慮するために，同定結果から犠牲陽極個々の分極モデル(電位と電流密度の関係式)の推定を行う．**Figure 15**中の点群は，ある1つの犠牲陽極表面の電位と電流密度の同定値をプロットしたものである．電流密度を一定として電流量を同定したため，点群が縦方向に伸びた状態となっている．ここで，分極モデルを線形な一次関数で近似する．すなわち，これらの点群の平均値を通り，定数項(自然電位)が1.06 Vである直線を，推定分極モデルとする．犠牲陽極の分極曲線も一般的に非線形であるが，本節においても対象とする犠牲陽極表面電位の変化幅が十分狭いため，自然電位から同定値のプロットの間の範囲で線形近似を行う．上記の推定を各犠牲陽極に対して行い， a を犠牲陽極の番号として分極抵抗 $R(a)$ の推定値を得る．また，土中鋼材についても，定数項が同定した切片電位となるように分極モデルを推定する．そして，推定された分極モデルを新たな境界条件として有限要素法順解析を行い，構造物周辺の電位を計算する．分極モデルの推定を行うことで，個々の電流量のばらつきを考慮した犠牲陽極発生電流量を推定することができる．さらに，順解析結果から構造物の任意の場所における表面電位を推定することも可能である．




Figure 15 Estimation of the anode polarization model

3.3 港湾施設における検証実験

3.3.1 解析対象施設の概要

本章では、港湾施設においてジャケット式栈橋構造物付近の電位を測定し、逆解析で犠牲陽極電流量を同定する。そして既設シャント抵抗の電流量を比較することで手法の検証を行う。2012年1月に検証実験を行った東京港大井埠頭新第5バースJ1ジャケットは、大型コンテナ船を接岸する港の外縁部分である。鋼材には、耐海水性ステンレス鋼被覆および流電陽極方式の電気防食が行われている。一部の犠牲陽極にシャント抵抗が取り付けられており、電流量の計測が可能である。

大井ジャケットは横幅約50m、奥行約35m、高さ約16mであり、主脚である12本の鋼材(レグ)は約25.8m(A.P.−12.5 m からA.P.−38.4 m)の鋼管杭により固定されている。A.P.(Arakawa Peil)は荒川水系における水準を表している。本稿における水深はA.P. を基準として表記する。鋼材はA.P.+3.4mからA.P.−1.5mの範囲は耐海水性ステンレス鋼が施されており、A.P.−1.5mからA.P.−15.0mは海中鋼材部、そしてA.P.−15.0mからA.P.−38.4mまでが土中鋼材部である。電気防食の設計上の防食電流密度は、海中部が130mA/m²、海底土中では30mA/m²であり。アルミニウム合金陽極(3.5A, 50年寿命)が108個設置されている。2002年に運用が開始され、現在は犠牲陽極からの電流量も安定している。

ジャケット全体のモデル図をFigure 16に示す。図中のNo. 1およびNo. 2の犠牲陽極にシャント抵抗が取り付けられている。水深はそれぞれA.P.−3.0m, A.P.−12.0mであり、電流量はNo. 1が0.9 A, No. 2が0.7 Aで、ともに0.02 Aの変動幅で推移していた。本検証ではこれらの値を犠牲陽極発生電流量の正解値とする。




Figure 16 The jacket model and measurement lines

3.3.2 現場での電位測定

電位測定では、ジャケット上部の足場より参照電極を投入し、**Figure 16**内に示す3か所の電位を、海面から海底まで0.5 mおきに測定した。図中の「Fix」は固定電極の位置を表す。移動電極には圧力センサーが付属しており、波による揺れを抑えるための重りを結び付けた。また足場において、測定点の水平方向の位置および海面の高さは、レーザー距離計を用いてジャケット天板との距離を測定することで得た。また水深は圧力センサーで測定し、海面の高さと合わせてジャケットとの相対位置関係を特定した。図中数値計算上の測定ラインは鋼材と接触しているが、それはレーザー距離計による位置測定に最大50 cm程度の誤差があると考えられるためであり、実際には移動電極は鋼材に接触していない。犠牲陽極No. 1およびNo. 2と測定ラインが最も近づいた時の距離はそれぞれ0.97m, 1.62mであった。海面の高さはA.P.+1.1 mであり、測定点数はそれぞれ22, 29, 30 点である。また海水の電気伝導率を海面から海底に向けて50cm間隔で、測定開始前と終了後に測定した。水平方向については、一つのジャケット構造物周辺では大きく変化しないと考えられるので鉛直方向のみを考慮した。電気伝導率は水深によらず3.56S/mとほぼ一定であった。

3.3.3 数値計算

数値計算に用いる有限要素法モデルを **Figure 17** に示す。解析領域としては、海中壁からの電流に対する測定値の感度及び有限要素法計算の負荷を考慮して、電位測定点を中心に周囲のレグが 6 本、犠牲陽極が 59 個含まれる領域のモデルを作成した。水深方向については、A.P.+1.1 m から A.P.-40.0 m の範囲でモデル化を行った。節点数は 1,043,239、要素数は 5,993,005 である。

未知数は、犠牲陽極、ステンレス鋼、土中鋼材、海中壁の電流量と、切片電位である。なお、犠牲陽極は**Figure 16**に示すように、水深ごとに3 グループに区切っている。個々の犠牲陽極の電流量は同一グループ内では同一であると仮定して、グループごとの電流量を同定する。また海中壁は4方向それぞれを未知としたため、未知数は計11個である。なお海中の電気伝導率は実測値より3.56S/m、土中の電気伝導率には代表値として1.0 S/mと入力した¹¹⁶。また、土中鋼材の分極抵抗は $1.0\Omega\text{m}^2$ とした。土中の電気伝導率および土中鋼材の分極抵抗の不確定性による影響は、1つのパラメータ $I_{\text{steel-soil}}$ に表れる。本解析では $I_{\text{steel-soil}}$ を同定するので、有限要素法計算の際、土中のパラメータは適当な文献値を用いれば良い。




Figure 17 FEM model of Ohi jacket structure

3.3.4 ベイズ推定の事前情報

本節ではベイズ推定の事前情報について述べる．まず海中鋼材分極抵抗の事前分布は，天然海水中で $-1000\text{mV vs. Ag/AgCl/sw}$ に約300日間保持したみがき鋼板の分極曲線(**Figure 18**)を測定し，現場測定データの電位域である， -900mV から -990mV の範囲で線形近似して取得した．そして，前後数十日の変動を基に，分極抵抗の平均値および標準偏差を定めた．これは防食状態に保たれた鋼材を模擬して，鋼材表面に石灰質被膜が生成した状態での分極抵抗を実験的に求めたものである．なお，数値計算の際の海中鋼材の表面電位は分極抵抗および切片電位により定まる．そのため分極抵抗の事前情報と真の値との誤差が小さい，すなわち分極抵抗の真の値がおおむね $1\sim 5\Omega\text{m}^2$ の範囲内であれば，海中鋼材表面電位を推定する際分極抵抗による誤差は，切片電位により相殺される．石灰質被膜は一定の厚さ以上には成長しないことから，分極抵抗の真の値も上記の範囲に収まると考えられる．したがって，上記の精度で分極抵抗の事前情報を得ることができれば，分極抵抗を未知として解析することが可能である．また犠牲陽極の電流量は規格値を，ステンレス鋼，土中鋼材の電流量については設計防食電流量を用いた⁴⁶．海中壁の電流量については先験情報がないため，平均値を0として，標準偏差の大きい事前分布を与えた．切片電位も，測定される電位がおおむね -800 mV から -1000 mV の範囲であるので，同様に標準偏差の大きい分布とした．なお R については事前分布に基づいた15通りの仮定値による計算結果を，事前分布に従って加重平均した．




Figure 18 Polarization curve of steel kept in the artificial sea water for 251, 293, and 329 days at 1000mV

3.3.5 同定結果と考察

ベイズ推定の事前情報，同定結果，そして正解値を**Table 3**に示す．AVEとSDは正規分布の平均値と標準偏差を示している．MAXとMINは同定値の最大値，最小値であり，それぞれ犠牲陽極電流量の安全側(消耗過大評価)，危険側(消耗過小評価)の推定結果を示している．シャント抵抗付犠牲陽極No. 1およびNo. 2はそれぞれグループ1，3に属し，電流量を見ると，同定値の標準偏差(1σ)内に正解値が収まっていることがわかる．本手法により，犠牲陽極の電流量を，平均値による見積もりでは誤差12%，安全側の見積もりでは36%，危険側の見積もりでは24%以内の精度で同定できることが確認できた．また，各測定場所における電位分布の測定値(Measured)と同定値(Identified)を**Figure 19**, **Figure 20**, **Figure 21**に示す．縦軸は水深を，横軸はグラウンドとの電位差を示している．まず海面付近で電位が貴化しているのはステンレス鋼にカソード電流が流入しているためである．そして水深4m，13m付近で電位が卑化し，電位のピークが現れているのは，測定ラインが犠牲陽極の直近を通っているためである．

Position 1は，2，3と比べて構造物との距離が大きいので，水深4mにおけるピークが測定されなかった．測定時に参照電極の位置誤差の影響が大きい犠牲陽極付近を除いて，同定値が測定値をほぼ再現できている．なお今回は測定場所の関係上，1本のレグに対して3か所の電位分布を取得したが，実用上は各レグ1か所ずつ，水平方向に2 m以内の距離で電位分布を測定することができれば，本実験の結果と同じ精度で電流量を同定できることを数値実験により確かめている．その他の境界の電流量同定結果については，ステンレス鋼では電流量が流入を表すマイナスの値となり，カソード電流が流れ込んでいると考えられる．電流密度に換算すると -34.662mA/m^2 となり，石灰質被膜や潮汐の影響を考慮しても妥当な値である，土中鋼材については同定値の標準偏差が大きく，不確定性の大きい結果となった．海底の形状が厳密に平らでないことや，海底付近の測定点が少ないことが原因として挙げられる．しかし，一般的に海底土は海水に比べて電気伝導率が低く，土中鋼材へ流れる電流量は犠牲陽極の総電流量に比べて小さいため，犠牲陽極電流量の同定値への影響は小さいと考えられる．また，海中壁については，解析領域に電流の流入出が見られた．領域内に不均一な電位分布があることを示している．土中鋼材同様，電流の総量が小さいため，同定結果への影響は小さいと考えられる．解析領域の境界付近に測定点を配置し，海中壁付近の情報量を増やすことで，海中壁の電流量についての同定精度は改善すると考え

られる。

Table 3 A priori information, the result of inverse analysis of the Ohi experiment, and correct values

Parameter	A priori information			Identified value			Correct value
	Ave	SD	Ave	SD	Max	Min	
$R [\Omega\text{m}^2]$	2.18	0.4	2.18	0.59	2.77	1.59	
$I_{\text{anode}(1)} [\text{A}]$	1.5	1	0.793	0.11	0.903	0.683	0.9
$I_{\text{anode}(2)} [\text{A}]$	1.5	1	1.095	0.125	1.22	0.97	-
$I_{\text{anode}(3)} [\text{A}]$	1.5	1	0.77	0.183	0.953	0.587	0.7
$i_{\text{stainless}} [\text{mA}/\text{m}^2]$	-130	50	-34.662	8.014	-26.647	-42.675	
$i_{\text{steel-soil}} [\text{mA}/\text{m}^2]$	-10	10	-0.071	5.788	5.717	-5.859	
$I_{\text{sea}(1)} [\text{A}]$	0	5	1.197	4.87	6.067	-3.673	-
$I_{\text{sea}(2)} [\text{A}]$	0	5	-0.217	4.324	4.107	-4.542	-
$I_{\text{sea}(3)} [\text{A}]$	0	5	-2.729	1.76	-0.968	-4.488	-
$I_{\text{sea}(4)} [\text{A}]$	0	5	1.872	3.182	5.052	-1.312	-
$\phi_{\text{offset}} [\text{V}]$	1	1	0.872	0.019	0.891	0.854	

次に犠牲陽極分極モデルの推定を行う。推定により得られた新たな境界条件をまとめて**Table 4**に示す。犠牲陽極の分極抵抗および土中鋼材の分極抵抗は推定した分極モデルを、それ以外は同定した電流量および切片電位を境界条件に用いた。推定した分極抵抗および有限要素法順解析で求めた電流量の最大値、平均値、最小値をグループごとに**Table 5**に示す。各グループ内の犠牲陽極において分極抵抗では最大約 $0.03\Omega\text{m}^2$ 、電流量では最大約 0.007 A のばらつきが見られる。また、順解析結果から再計算した、測定ラインにおける電位分布(Estimated)を**Figure 19, Figure 20, Figure 21**に示す。Estimatedの結果では、犠牲陽極個々の電流量ばらつきを考慮していながら、犠牲陽極の電流量が各グループ内で同一と仮定した解析結果(Identified)とほぼ同じ電位分布を与えており、推定した境界条件の妥当性が確認できる。




Figure 19 Voltage distributions of the measured, identified, and estimated results (Position 1)




Figure 20 Voltage distributions of the measured, identified, and estimated results (Position 2)




Figure 21 Voltage distributions of the measured, identified, and estimated results (Position 3)

Table 4 FEM boundary conditions derived from the estimation results of the polarization model

Boundary	Place	Boundary conditions
Γ_a	Sacrificial anode	$\phi = -R(a)i + 1.06$ [V]
Γ_{c1}	Steel (Sea section)	$\phi = -2.18i + 0.872$ [V]
Γ_{c2}	Steel (Soil section)	$\phi = -1071.081i + 0.872$ [V]
Γ_{c3}	Stainless	$I = -34.662$ [mA/m ²]
$\Gamma_{sea(1)}$	Sea wall 1	$I = 1.197$ [A]
$\Gamma_{sea(2)}$	Sea wall 2	$I = -0.217$ [A]
$\Gamma_{sea(3)}$	Sea wall 3	$I = -2.729$ [A]
$\Gamma_{sea(4)}$	Sea wall 4	$I = 1.870$ [A]
Γ_{air}	Sea surface	$I = 0$ [A]
Γ_{soil}	Soil wall	$I = 0$ [A]

Table 5 Estimated anode surface resistances and the current value with the new boundary conditions

Estimated parameter	Group 1	Group 2	Group 3
$R_{max}[\Omega m^2]$	0.149	0.081	0.163
$R_{ave}[\Omega m^2]$	0.129	0.062	0.13
$R_{min}[\Omega m^2]$	0.111	0.051	0.096
$I_{max}[A]$	0.794	1.105	0.769
$I_{ave}[A]$	0.792	1.098	0.767
$I_{min}[A]$	0.791	1.094	0.765

3.4 データサイエンス技術を活用した今後の展望

本研究では、鋼材の表面抵抗 R_S に関するベイズ推定の事前情報として、天然海水を用いた水槽試験を用いて、石灰質被膜付着を模擬した鋼材試験片から分極曲線を取得し、現場で測定された電位域で線形近似した傾き R_S を用いている。しかし、実環境においては海水温度や成分等が変化することが想定され、鋼材の表面状態は水槽試験と同様にならないと考えられる。事前情報に誤差がある場合、最終的には犠牲陽極電流量の推定誤差もしくは誤差分散の増大につながるため、より正確な R_S の事前情報取得が求められる。そこで、異なる海水環境で運用される複数の海洋構造物データを用いて機械学習を行い、環境違い時における R_S 補正予測モデルを構築することが考えられる。

機械学習を活用した鋼材表面の環境影響学習コンセプトを **Figure 22** に示す。まず、学習の入力データとして、海水特性情報、構造物の材料情報、および現状用いている水槽試験の結果を与える。海水特性としては平均水温や電気伝導度、材料情報としては、犠牲陽極や鋼材、およびステンレス鋼ライニングの材料が入力となり得る。また、水槽試験からは試験日数および分極曲線を用いて、 R_S の確率分布を生成する。これらを、ニューラルネットワークを用いた機械学習モデルに学習させる。次に、教師データとして、

本章で開発した手法を用いた R_s 推定結果を与える．すると水槽試験の情報を基にして，海水特性および鋼構造物の材料情報を反映した R_s 補正結果をモデル出力として得ることが可能となる．これを複数サイトにおける海洋鋼構造物データで学習させることで，環境違い時の R_s を高精度に予測することが可能となる．その結果，事前情報の信頼度が向上し，犠牲陽極発生量の推定精度が改善する．さらに，新規サイト建設前に現場の海洋環境データを取得すれば，当該海域における防食状態の事前アセスメントが可能となる．このように，実環境のモデリングが困難な部位に局所的に機械学習を用いたアプローチを適用することで，さらなる予測精度の改善が期待できると考えられる．




Figure 22 Compensation concept of the surface resistance of the steel by utilizing machine learning

3.5 まとめ

社会インフラの1つである大型海洋鋼構造物の電気防食状態を間接的にモニタリングする手法として、構造物周辺の海水電位測定から犠牲陽極の発生電流量を推定する逆解析手法を開発した。具体的な取り組みは以下の通りである。

- (1) 海洋鋼構造物周辺における海水中の電位測定結果と、数値解析を用いた電位計算結果より、犠牲陽極からの発生電流量および構造物表面電位を推定する逆解析手法を構築した。
- (2) 構造物形状情報および海中の電気伝導率情報から、ジャケット構造物1基分の有限要素法解析モデルを構築し、実環境を模擬して海水中電位応答を計算した。
- (3) ベイズ推定理論に基づき、パラメータの不確定性を考慮した観測方程式を構築し、電位測定結果と数値計算結果、および水槽実験で得られた技術的知見から逆解析により犠牲陽極の発生電流量を同定した。
- (4) 逆解析を実際のジャケット式栈橋構造の海洋鋼構造物に適用し、犠牲陽極の電流量を、同定値の標準偏差(1σ)以内に正解値が収まる精度で同定出来ることを示した。
- (5) 今後、機械学習を用いて、実環境のモデリングが困難な部位の境界条件を推定させることで、さらなる予測精度の改善が期待できる。

第4章 データ同化を用いた犠牲陽極電流量予測システムの開発

4.1 はじめに

前章にて、数値解析を用いた新たな防食検査法として、実際の鋼構造物周辺の電位測定値から逆解析を用いて犠牲陽極の電流量および構造物表面電位を推定する手法を開発した。本章では、データ同化を用いて現場の情報を蓄積し、より高精度な犠牲陽極電流量予測を行うシステムを開発する。本予測システムでは、技術的知見から次の時刻における電流量を予測するシステムモデル、予測値を現場の観測値を用いて修正する観測モデルを組み合わせることにより、現場の測定情報を反映した犠牲陽極電流量予測を行う。

4.2 解析手法

4.2.1 電気防食予測システム概要

電気防食予測の流れを**Figure 23**に示す。本システムにおける推定値は犠牲陽極の発生電流量、観測値は構造物周囲の海水中の電位である。本システムは時間更新、観測更新と2つの更新ステップから成り立つ。時間更新ステップは、犠牲陽極分極抵抗の経時変化をモデル化したシステムモデルに基づいて、次の時刻における分極抵抗を予測し、数値計算により電流量予測値を得るステップである。通電開始後の犠牲陽極は一般的に、アノード反応による自身の消耗や腐食生成物の付着、カソード側の鋼材表面への石灰質皮膜付着による分極抵抗増加により、発生電流量は低減していく。しかし、実環境において全ての解析パラメータを直接測定することはできず、システムモデルのみで電流を定量的に予測することは困難である。そこで次の観測更新ステップでは、数値計算により構築される観測モデルに基づいて、時間更新で予測された電流量を現場の観測値により修正する。このプロセスには、前章で開発した犠牲陽極電流量推定法を用いる。なお、時間更新は必ずしも観測更新と同時刻に行う必要はない。これら2つの更新ステップを繰り返し、現場の情報を蓄積することにより、予測システムの精度を向上させる。

4.2.2 計算フロー

データ同化の計算フローを**Figure 24**に示す。 $X_{t+1|t}$ は時刻 t までの観測値から推定された時刻 $t+1$ における推定値である。グラフ縦軸は利用している観測値の時刻を表しており、横軸は実時間を表している。まず、分極抵抗の初期値 $R_{Al(0|0)}$ より有限要素法(以下 FEMと記す)で順計算を行い、初期電流量 $I_{Al(0|0)}$ を計算する。次に $R_{Al(0|0)}$ 、 $I_{Al(0|0)}$ から1年目の分極抵抗 $R_{Al(1|0)}$ を、システムモデルに基づき予測する(時間更新)。次に観測更新を適用するために、分極抵抗 $R_{Al(1|0)}$ から FEM順計算を行い、グループごとの電流量 $I_{Al(1|0)}^{group}$ を求める。そして、 $I_{Al(1|0)}^{group}$ を事前情報として観測値からベイズ推定を行い、電流量 $I_{Al(1|1)}^{group}$ を同定する(観測更新)。最後に分極モデルの推定を行い、グループごとの電流量を個々の分極抵抗 $R_{Al(1|1)}$ および電流量 $I_{Al(1|1)}$ に換算する。 $R_{Al(0|0)}$ 、 $I_{Al(0|0)}$ から $R_{Al(1|1)}$ 、 $I_{Al(1|1)}$ を求めるプロセスを1サイクルとして、2年目以降も同様の計算を行う。なお将来予測、すなわち時間更新のみを行う場合は、時間更新による予測値をそのまま次の時間更新の入力値とする。

4.2.3 数理モデルの設定

[1] 支配方程式

本研究の適用対象であるジャケット構造物のモデルを**Figure 25**に示す。構造物形状情報、海水中および海底土の電気伝導率、そしてカソードの分極曲線を線形近似したデータを用いて、FEMにより海水中の電位計算を行う。本研究における検査対象では、測定される電位の最大値と最小値の差が100mV以内であるので、その範囲内では分極曲線を線形とみなす。解析領域として、構造物周辺の海水および海底土で満たされた領域 Ω を考える。領域の境界は、犠牲陽極表面のアノードとなる境界 Γ_a 、骨組の鋼材で、カソードとなる境界 Γ_{c1} 、 Γ_{c2} (それぞれ海水中、海底土中の鋼材を表す)、海面付近の耐海水性ステンレス鋼でカソードとなる境界 Γ_{c3} 、海水を仮想的に分割した海水中領域の鉛直面境界(以下、海水中壁と呼ぶ) Γ_{sea} 、海水中領域の上部の境界 Γ_{air} 、そして海底土を仮想的に分割した海底土中領域の境界 Γ_{soil} で囲まれる。

領域内および境界上の電位を ϕ 、境界上の法線方向の電流密度を i 、領域内の電気伝導率を κ とする。本論文では解析上、電位 ϕ は金属に対する海水の電位を考えているため、通常電気化学で用いる、溶液に対する金属の電位の符号を逆転させて用いる。領域においてイオンの損失や増加が生じないとし、海水中と海底土中領域の電気伝導率が不均一である点を考慮すると、領域内の電位 ϕ は支配方程式として式(87)を満足する。

$$\nabla \cdot (\kappa \nabla \phi) \quad (87)$$

また境界上の電流密度は、式(88)で表される。 $\partial/\partial n$ は外向き法線方向微分を表す。

$$i \equiv \kappa \frac{d\phi}{dn} \quad (88)$$




Figure 25 Boundary conditions of a jacket structure in the cathodic protection

[2] 時間更新ステップにおける境界条件

時間更新，観測更新の際に行うFEM順計算の境界条件をTable 6に示す．これらの条件のもと，式(87)を数値解析で解くことで，領域内における電位や，各境界からの電流量の計算を行う．まず時間更新ステップでは，現在の時刻における推定値およびシステムモデルによる分極抵抗予測値を入力パラメータとしてFEM順計算を行い，次の時刻における電流量予測値を計算する．犠牲陽極，海水中鋼材，耐海水性ステンレス鋼には金属境界条件として，金属の分極曲線を線形近似したものを用いる． $R_{Al}(a)$ ， R_S ， R_{sus} はそれぞれの金属の分極曲線の傾きで，分極抵抗を表す． $a(=1, 2, \dots)$ は犠牲陽極の番号である． ϕ_S ， ϕ_{sus} はそれぞれの分極曲線近似直線の定数項であり，以後切片電位と称する．また，海底土中鋼材と海水中壁には，それぞれの電流量 $I_{steel-soil}$ ， $I_{sea}(n)$ により決まる電流密度を与える． $n(=1, 2, 3, 4)$ は壁の番号である． $i_1(I)$ は総電流量が I となる一様電流密度を表す．また，海面および海底土中における外壁は，時間更新，観測更新ともに絶縁境界として扱う．すなわち，領域外への電流の流入出は海水中壁 Γ_{sea} のみから起こると仮定する．海面は絶縁であり，また海底土は電気伝導率が低く，海底土中レグへ流れ込む電流は主に海水中領域の犠牲陽極から供給されるため，海底土中境界からの電流の流入出は無視できると考えられるためである．

Table 6 Boundary conditions for FEM

Boundary	Place	Boundary conditions (Time update)	Boundary conditions (Observation update)
$\Gamma_a(a)$	Sacrificial anode (a)	$\phi = -R_{Al}(a)i + 1.06$ [V]	$i = i_1(I_{Al}(a))$ [mA/m ²]
Γ_{c1}	Steel (Sea section)	$\phi = -R_S i + \phi_{offset}$ [V]	$\phi = -R_S i + \phi_{offset}$ [V]
Γ_{c2}	Steel (Soil section)	$i = i_1(I_{steel-soil})$ [mA/m ²]	$i = i_2(I_{steel-soil})$ [mA/m ²]
Γ_{c3}	Stainless	$\phi = -R_{sus}i + \phi_{sus}$ [V]	$i = i_1(I_{sus})$ [mA/m ²]
$\Gamma_{sea(n)}$	Sea wall (n)	$i = i_1(I_{sea}(n))$ [mA/m ²]	$i = i_1(I_{sea}(n))$ [mA/m ²]
Γ_{air}	Sea surface	$I = 0$ [A]	$I = 0$ [A]
Γ_{soil}	Soil wall	$I = 0$ [A]	$I = 0$ [A]

[3] 観測更新ステップにおける境界条件

観測更新ステップでは、各境界からの単位電流量あたりの測定点における電位変化を求め、観測行列を作成する。鋼材分極抵抗 R_S は時間更新で予測された値を、各境界からの電流量 $I_{Al}(a)$, $I_{steel-soil}$, I_{sus} , $I_{sea}(n)$ および切片電位 ϕ_S は仮の値を与えて計算を行う。この際、位置関係の近い複数の犠牲陽極は1つのグループにまとめ、グループごとの電流量は同一として扱う。海水中鋼材に対しては時間更新ステップと同様に、金属境界条件として鋼材の分極曲線を線形近似したものを用いる。石灰質皮膜が付着した状態における鋼材分極抵抗の事前分布は、鋼材試験片を用いた実験により得た分極曲線を、測定データの電位域で線形近似して取得した。犠牲陽極、耐海水性ステンレス鋼、海水中壁には一様電流密度 $i_1(I)$ を与える。FEM計算において、モデルの線形化および未知パラメータの減少により、計算量を軽減するためである。海底土中鋼材には電流密度が地下深くなるにつれて低減するという、代表的な分布形状 $i_2(I)$ を与える。すなわち、各犠牲陽極から1 Aずつ電流を発生させ、海底土中鋼材への電流流入がある状態と、海底土中鋼材表面を絶縁とした状態における解析結果の差を取り、流入した総電流量で除すことで $i_2(I)$ を構成した。なお、海底土中鋼材へ電流流入がある状態の境界条件としては、海底土中鋼材分極抵抗として $1\Omega m^2$ 、海底土中電気伝導率代表値 $1.0S/m^{116}$ を用いた。

4.2.4 システムモデル(時間更新式)

犠牲陽極の消耗と腐食生成物の付着、鋼材表面への石灰質皮膜の付着をモデル化し、一時刻先の分極抵抗を予測するモデル構築を行う。本研究における解析では、犠牲陽極の発生電流量 I の他に、耐海水性ステンレス鋼、海底土中鋼材、解析領域の外壁からの電流量、海水中鋼材分極抵抗、そして切片電位を推定値とし、これらの推定値の確率分布をまとめて $\mathbf{X} = N(\hat{\mathbf{X}}, P)$ と表記する。 N はガウス分布を表し、括弧内の成分はそれぞれ平均値、分散行列である。システムモデルによる推定値の時間更新式は、式(89)で表される。

$$\mathbf{X}_{t+1|t} = f_t(\mathbf{X}_{t|t}, v_{model}) \quad (89)$$

f_t は非線形システムモデル， $v_{\text{model}} = N(\bar{v}_{\text{model}}, P_{\text{model}})$ はシステムノイズの確率分布を表す．本研究では確率分布は全て正規分布であり，期待値，分散の時間更新式は式(90)(91)のように表される．

$$\bar{\mathbf{X}}_{t+1|t} = f_t(\bar{\mathbf{X}}_{t|t}) + v_{\text{model}} \quad (90)$$

$$P_{t+1|t} = f_t(P_{t|t}) + P_{\text{model}} \quad (91)$$

非線形システムモデル f_t では以下の項に従って犠牲陽極と鋼材の分極抵抗を更新して，新たな境界条件によりFEM順計算を行うことにより，次の時刻における推定値 $\mathbf{X}_{t+1|t}$ を予測する．

[1] 犠牲陽極の消耗による犠牲陽極分極抵抗の増加

犠牲陽極は自身の消耗により表面積が減少し，電流量が低減する．本研究ではFEMモデル内の犠牲陽極のサイズは変えずに，犠牲陽極の分極抵抗を増加させることにより，等価的に消耗の影響を表現する．棒状の犠牲陽極は一般的に，長手方向の長さ L を保ちながら周長が減少し，細くなっていく．そこで，犠牲陽極の溶解による質量損失を，等価半径の減少による質量減少とみなし，時刻 $t+1$ における犠牲陽極の等価半径 r_{t+1} を式(92)のように表す．

$$r_{t+1} = \sqrt{r_t^2 - \frac{I_t \Delta t M}{\pi L n F \rho}} \quad (92)$$

ここで， I_t は時刻 t における犠牲陽極の電流量， Δt は通電期間， F はファラデー定数， M はアルミニウムの原子量， n は価数， ρ は密度である．次に，次の時刻 $t+1$ における分極抵抗予測値 $R_{Al(t+1|t)}$ を求める．棒状陽極の接地抵抗 R'_{Al} は，電解質の電気伝導率を κ として，以下の式(93)で表される¹¹⁷．

$$R'_{Al} = \frac{1}{2\pi L \kappa} \left(\ln \frac{2L}{r} - 1 \right) \quad (93)$$

そして，FEMモデル上の犠牲陽極の表面積を S_{model} とすると，分極抵抗予測値は式(94)のように表せる．

$$R_{Al(t+1|t)} = R_{Al(t|t)} + \frac{S_{\text{model}}}{2\pi L \kappa} \ln \left(\frac{r_t}{r_{t+1}} \right) \quad (94)$$

式(92)と(94)を順次計算することで，犠牲陽極分極抵抗の更新を行う．

[2] 犠牲陽極表面への腐食生成物生成による分極抵抗の増加

犠牲陽極には消耗による分極抵抗の増加に加えて，溶解に伴う表面への腐食生成物の生成による分極

抵抗増加も発生する．そこで，犠牲陽極から発生した総クーロン量に比例して分極抵抗が増加するモデルを考える．具体的には，式(94)で分極抵抗を更新した後に，式(95)にしたがって，もう一度分極抵抗を更新する．

$$R_{Al(t+1|t)} = \Delta R_{Al} \frac{I_{Al(t|t)} \Delta t}{Q_{Al}} + R_{Al(t|t)} \quad (95)$$

ΔR_{Al} は分極抵抗上昇幅， Q_{Al} は，犠牲陽極の設計電流量である3.0Aの電流が2年間発生した場合のクーロン量である．今回は実測データ⁴⁶を参考に， $\Delta R_{Al}=0.05\Omega m^2$ とした．犠牲陽極への腐食生成物の生成は，表面における孔食といったランダム現象に起因するため，パラメータを予測することは困難である．そこで時間更新ステップでは， ΔR_{Al} を実測データより1つの値に固定し，観測更新ステップにおいて分極抵抗を修正する．

[3] 鋼材表面への石灰質皮膜生成による分極抵抗の増加

カソード側の鋼材でも，鋼材表面に石灰質皮膜が形成され，表面の分極抵抗が増加する．そこで，鋼材へ流れ込んだ総クーロン量に比例して皮膜が生成するモデルを考える．時刻 $t+1$ の鋼材の分極抵抗予測値 $R_{S(t+1|t)}$ を，以下の式(96)のように表す．

$$R_{S(t+1|t)} = \Delta R_S \frac{I_{steel(t|t)} \Delta t}{Q_S} + R_{S(t|t)} \quad (96)$$

ΔR_S は分極抵抗上昇幅， Q_S は，鋼材へ設計電流量である150A(電流密度 $i=130mA/m^2$)の電流が2年間流れた場合のクーロン量である．ただし，石灰質皮膜は一定の厚さ以上は生成しないことが知られている⁴⁶．石灰質皮膜は鋼材付近のアルカリ雰囲気でのみ生成するため，膜厚が増加して鋼材と離れると海水に溶解してしまうためである．そこで鋼材試験片を海水中で外部電源方式で18か月間防食し，石灰質皮膜を生成させ，この試験片の分極抵抗を計測し， $R_S = 2.18\Omega m^2$ を得た．計算ではこの値よりも分極抵抗が増加しないように上限を設定した．これらの境界条件を揃えた上でFEM計算を行い，犠牲陽極電流量の予測値を求める．

4.2.5 観測モデル(観測更新式)

[1] 観測方程式

ここでは，観測更新に用いる観測方程式の構築について述べる．本研究で扱う静電場解析では，領域内の電位 ϕ は支配方程式として式(87)を満足する．したがって，式(97)で表される観測方程式が成立する．

$$\phi'_t = A_t(R_S)X_{t|t} + \varepsilon \quad (97)$$

ϕ'_t は時刻 t における m 個の測定値 $\phi'_1(t), \phi'_2(t), \dots, \phi'_m(t)$ からなる列ベクトル, $\mathbf{X}_{t|t}$ は各境界からの発生電流量および切片電位からなる列ベクトルである. また $A_t(R_S)$ は鋼材分極抵抗 R_S に依存する観測行列, $\varepsilon = N(\bar{w}, W)$ は測定誤差やモデル誤差等をまとめたものである. R_S に仮の値を与えてFEM順計算を行い $A_t(R_S)$ の各成分を求めることにより, 観測方程式を構築する.

[2] ベイズ推定による未知数の同定

観測方程式(97)により, 電位の測定値 ϕ'_t から未知数 $\mathbf{X}_{t|t}$ を同定する. その際ベイズ推定により, 電位測定値の持つ誤差や, モデルのパラメータが持つ不確定性による, 同定精度への影響の評価, そして事前に蓄積された情報を利用した同定結果の補正を行う. 不確定性をもつパラメータである電位の測定誤差や鋼材分極抵抗, 各境界の電流値, 切片電位の事前情報を事前分布として正規分布で表現する. 事前情報には, 一時刻前の時刻における推定値およびシステムモデルによる予測値を用いる. R_S の事前分布 $p(R_S)$ を用いて R_S に仮定値を与え, 推定尤度分布の平均値 $\hat{\mathbf{X}}_{t|t}(R_S, \phi')$ および分散共分散行列 $P_{t|t}(R_S)$ を式(98), (99)に従い計算する. そして, それら計算結果を R_S 仮定値の出現確率に基づき加重平均を行う形で式(100)を計算することで, 測定値 ϕ'_t を得たときの同定値 $\mathbf{X}_{t|t}$ の尤度分布 $\mathcal{L}(\mathbf{X}_{t|t}|\phi'_t)$ を得る. $\varepsilon = N(\bar{w}, W)$ は電位の測定誤差の事前分布を表す. N はガウス分布を表し, 括弧内の成分はそれぞれ平均値, 分散行列である. T は転置を表す.

$$\hat{\mathbf{X}}_{t|t}(R_S, \phi') = \hat{\mathbf{X}}_{t|t-1} + P_{t|t-1}(R_S)A_t^T(R_S)W^{-1}\{\phi'_t - (A_t(R_S)\hat{\mathbf{X}}_{t|t-1} + \bar{w})\} \quad (98)$$

$$P_{t|t}(R_S) = (A_t^T(R_S)W^{-1}A_t(R_S) + P_{t|t-1}^{-1})^{-1} \quad (99)$$

$$\mathcal{L}(\mathbf{X}_{t|t}|\phi'_t) = \int N(\hat{\mathbf{X}}_{t|t}(R_S, \phi'), P_{t|t}(R_S))p(R_S)dR_S \quad (100)$$

期待値, 分散の観測更新式は式(101)(102)のように表される. T は転置を表す.

$$\hat{\mathbf{X}}_{t|t} = \int (\hat{\mathbf{X}}_{t|t}(R_S)p(R_S))dR_S \quad (101)$$

$$P_{t|t} = \int (P_{t|t}(R_S) + \hat{\mathbf{X}}_{t|t}(R_S)\hat{\mathbf{X}}_{t|t}^T(R_S))p(R_S)dR_S - \hat{\mathbf{X}}_{t|t}\hat{\mathbf{X}}_{t|t}^T \quad (102)$$

[3] 分極モデル推定による再計算

ここでは同定した犠牲陽極のグループごとの電流量 $I_{Al(t|t)}^{\text{group}}$ から, 個々の分極抵抗 $R_{Al(t|t)}$ および電流量 $I_{Al(t|t)}$ を得る方法について述べる. 同じグループに属する犠牲陽極は, 位置関係等により電流量が異なるため, 前項で同定した電流と等しいとは限らない. しかし犠牲陽極は同じ材質であり, 近接して取り付けられた場合はほぼ同じ環境下で通電していることになるため, 近接した犠牲陽極の分極曲線は等し

いと考えられる。したがって、前項で同定した犠牲陽極表面の電流密度、電位から犠牲陽極個々の分極モデルを推定し、それらを新たな境界条件としてFEM順計算を行うことで、取り付け位置によるばらつきを考慮した犠牲陽極個々の電流量を推定することができる。Figure 26を用いて陽極分極モデル推定の方法を説明する。まず個々の犠牲陽極について、同定した電流密度・電位をグラフにプロットする。そして点群の平均値を通り、定数項(自然電位)を1.06Vとした回帰直線を引き、推定分極モデルとする。犠牲陽極の分極曲線は一般的に非線形であるが、本節においても対象とする犠牲陽極表面電位の変化幅が十分狭いため、線形近似が可能である。上記の推定を各犠牲陽極に対して行い、得られた分極抵抗を新たな境界条件としてFEM順計算を行う。そして、得られた電流量を最終的な推定値とする。




Figure 26 Estimation of anode polarization model

4.3 数値実験による電流予測精度検証

4.3.1 数値実験概要

本章では、実環境を模擬したFEM順計算を行い、あらかじめ指定した測定点における電位を出力し、誤差を付加して模擬電位測定値とする。そして模擬測定値に対して本システムを適用し、犠牲陽極電流量を推定する。数年分の現場の情報を蓄積した時点から時間更新ステップのみの将来予測を行い、FEM計算により直接得られる電流量の正解値と比較することで、本システムのモニタリング精度を検証する。模擬対象であるジャケット栈橋構造物のFEMモデル図をFigure 27に示す。




Figure 27 FEM model for the jacket structure

4.3.2 模擬データの作成

模擬測定値作成のためのシステムモデルのパラメータをTable 7の上側の行(Exact value)に示す。まず、鋼材側の分極抵抗初期値は、分極抵抗 $1.0\Omega\text{m}^2$ 、鋼材の切片電位は実環境における電位変化を模擬して、0年目のみ 0.67V 、1年目以降は 0.82V とした。また鋼材分極抵抗の上昇幅 ΔR_s は $3.0\Omega\text{m}^2$ 、上限値 $R_{s\text{limit}}$ は $4.0\Omega\text{m}^2$ とした。次に犠牲陽極については、分極抵抗の初期値が $0.002\Omega\text{m}^2$ 、上昇幅を $0.1\Omega\text{m}^2$ とした。ステンレス鋼については、 $R_{\text{SUS}}=3.0\Omega\text{m}^2$ 、 $\phi_{\text{SUS}}=0.3\text{V}$ とし、海水中の電気伝導率は 3.56S/m 、海底土中の電気伝導率は 1.0S/m とした。上記のパラメータを用いて、システムモデルのみによる計算を繰り返し、模擬測定値を作成する。測定値には、最大 5mV のランダム誤差を付加した。今回は測定点として、レグ1本あたり2か所、合計12か所において海面から海底面までの電位分布を測定することを想定した。レグまでの距離はおおむね 0.5m 以内である。数値実験における電位測定点をFigure 28に示す。また、その中のLine1における電位分布の経年変化をFigure 29に示す。なお、電位はAg/AgCl [sw] 電極電位を基準とした。グラフには奇数年目の模擬測定値を示しているが、データ同化は1年おきに行った。

Table 7 Boundary conditions for FEM analysis

Parameter	ϕ_{offset} [V]	ΔR_S [Ωm^2]	ΔR_{S_limit} [Ωm^2]	ΔR_{Al} [Ωm^2]
Exact value	0.67 (t=0) 0.82(t>0)	3.0	4.0	0.1
System model	0.77	1.0	2.0	0.05




Figure 28 Locations of voltage measurement lines for the numerical experiment




Figure 29 Voltage distributions at the measurement position over years

Figure 30 に、数値実験で設定した 12 本の測定ラインそれぞれの 1 年目における電位分布を示す。各ラインごとに異なるグラフ概形となっている。これは、測定ラインと犠牲陽極や鋼材の距離が異なっているためと考えられる。例えば、Line 1 は水深 6m と 12m にて 2 つのピークを持っており、これはそれらの水深において測定ラインが犠牲陽極の近傍を通過しており、電位が上昇したためと考えられる。**Figure 31** に FEM モデルに含まれる 59 個の犠牲陽極、個々の電流量の経時変化を示す。各犠牲陽極と鋼材との相対位置関係が異なるため、犠牲陽極ごとに発生している電流量が異なっていることが確認できる。このように、数値実験の FEM モデル内においては、模擬測定値の電位および犠牲陽極電流量が部位ごとに異なっており、実環境を想定した模擬測定値としては十分なばらつきを有する。




Figure 30 Voltage distributions of twelve measurement lines (year 1)




Figure 31 Current of 59 individual sacrificial anodes

4.3.3 データ同化による推定結果

時間更新ステップに用いたシステムモデルのパラメータを**Table 7**の下側(System model)に示す。鋼材分極抵抗および犠牲陽極分極抵抗の初期値は正解値と同じとした。切片電位、犠牲陽極分極抵抗上昇幅、鋼材分極抵抗上昇幅、上限値は正解値と異なるものとした。また、観測更新における犠牲陽極のグループ分けを**Figure 32**に示す。まず6本のレグA1からB3においてそれぞれの周辺6グループに分け、さらに水深によりUpper, Middle, Lower の3グループに分け、合計18グループとした。

Figure 28内における犠牲陽極1の電流量について、正解値(Correct Value) , 毎年情報を蓄積したデータ同化による推定値(Data Assimilation), システムモデルのみによる予測値(Only System Model Update), 前年の情報を利用せず観測モデルを毎年独立で用いた推定値(Only Observation Model Update), そして5年分の測定情報をデータ同化で蓄積した後にシステムモデルによる予測した値(Forecasted Value after 5 Years Data Assimilation)を**Figure 33**に示す。本システムによる推定値は、初期は正解値と異なるものの、電位測定データを同化し始めた1年目以降は正解値に近づき、点線で示される標準偏差内の誤差を持って推移している。それに対してシステムモデルのみによる予測値は、切片電位や犠牲陽極の分極抵抗変化等の実環境で変動するパラメータに追従することができず、正解値と大きく異なった値を取ってしまう。また観測モデルを独立に用いた場合の推定値も、電流が低減した10年後以降は電流を正解値より大きく見積もっている。現場情報の蓄積が無く、観測更新の際に与えるベイズ推定の事前情報に犠牲陽極設計電流値を与えているため、電流量が大きく見積もられるためと考えられる。次に測定情報を5年蓄積した上での将来予測値は、10年後まで正解値との誤差が最大0.2 A以内となった。電流量が初期に比べて安定しているのは、通電開始から2, 3年程度経過すると鋼材側の石灰質皮膜が安定化するためである。したがって、電流量が大きく変化する通電初期にデータ同化を行っておくことで、その後はシステムモデルのみによる予測、すなわち将来予測が可能となると考えられる。**Figure 34**には犠牲陽極11の電流量について、同様の予測を行った結果を示す。犠牲陽極11は、犠牲陽極1に比べて電流値の正解値が低減するペースが速く、同じ年度での電流量正解値は犠牲陽極11の方が小さい。データ同化による予測結果の正解値に対する上下関係は、犠牲陽極1とは異なる推移を示すものの、犠牲陽極11においても正解値に最も良く追従したのはデータ同化を行った結果であった。このように、FEMモデル内で異なる電場環境に置かれた他の犠牲陽極に対しても、データ同化による電流量推定が可能であることが確認できた。




Figure 32 Grouping of sacrificial anodes in the numerical experiment




Figure 33 Estimated result of the numerical Experiment (Anode 1)




Figure 34 Estimated result of the numerical Experiment (Anode 11)

4.4 数値実験による犠牲陽極の脱落検知精度検証

4.4.1 犠牲陽極の脱落検知精度について

鋼構造物に取り付けられた犠牲陽極は、船舶の接触といった運用中のトラブルや、施工不良により、途中で脱落または通電が切れ、機能を果たさなくなる恐れがある(以後、脱落と称する)。したがって、本システムにおいても現場の情報を蓄積する際に、脱落が起きていた場合には、適切に検知する必要がある。そこで、犠牲陽極が10年目で脱落したと仮定して電位の模擬測定値を作成し、本システムの犠牲陽極脱落検知検証の検証を行った。

4.4.2 模擬データの作成

模擬測定値作成のためのシステムモデルのパラメータは、前章の**Table 7**と同様である。10 年目までは通常の更新を行い、11年目において複数の犠牲陽極の分極抵抗を $1.0 \times 10^6 \Omega\text{m}^2$ と変更し、対象の犠牲陽極の機能を失わせる。そしてその後5年分の計算を行い、合計15年分の模擬データを取得する。脱落させた犠牲陽極は**Figure 35**内の犠牲陽極AからJまでの、計10個である。3本のレグ周辺において、同じグループに属する犠牲陽極を全て脱落させている。また、15年分のLine 1に沿った電位分布を**Figure 36**に示す。脱落が起きた11年目に電位が大きく貴化していることがわかる。




Figure 35 Deactivated anodes (A~J) in the numerical experiment




Figure 36 Calculated voltage distribution of the line 1 with 10 deactivated anodes at 11th year

4.4.3 解析結果（脱落個数3個以上）

11 年目において脱落させた10 個の犠牲陽極電流量，模擬正解値と推定結果の比較を示す．犠牲陽極 A, Dの電流量変化を**Figure 37**に，G, Kの電流量変化を**Figure 38**に示す．それぞれ11 年目の観測更新で電流量がほぼゼロと推定され，その後も最大0.15A 以下の範囲で推定値が推移しており，脱落したと判定することができる．犠牲陽極B, CはAと，E, F はDと，H, I, J はGと同じグループに属し，グループ内で電流量推定値は同様のトレンドを示した．また，脱落させていない49 個の犠牲陽極は11 年目以降も電流量が急減することなく推移した．例として健全な犠牲陽極Kの電流量推定値を見ると，11年目以降もそれまでと同様の低減トレンドを示した．以上の結果より，グループ内全ての犠牲陽極が脱落，すなわち3, 4 個の犠牲陽極が局所的に脱落した場合は，本手法により検知および場所の特定が可能であることが示された．




Figure 37 Comparison of the correct and estimated current (Left : Anode A, Right : Anode D)




Figure 38 Comparison of the correct and estimated current (Left : Anode G, Right : Anode K)

4.4.4 解析結果（脱落個数2個以内）

各グループは3個または4個の犠牲陽極で構成されるが、そのうち2個および1個のみ脱落の場合の検知、場所特定について検証を行った。まず脱落が2個の場合について、脱落させた犠牲陽極の位置を **Figure 39** に示す。矢印で示した犠牲陽極（Lack1,2）を脱落させたところ、脱落した犠牲陽極の電流量は減少することなく、代わりに丸印で示す6個の犠牲陽極の電流が急減少し、脱落と判定された。その際の Line1 における電位分布を **Figure 40** に示す。11年目以降、脱落による電位低下の様子が見られるが、10個脱落時の **Figure 36** に比べて変化量が小さいことがわかる。また脱落が1個の場合、図の矢印で示される犠牲陽極のうち、Lack1 を脱落させたのに対し、電流量が大きく増減する犠牲陽極が数個出現したが、電流値が有意な減少を示し脱落と判定できる犠牲陽極は出現しなかった。したがって、脱落個数がグループを構成する犠牲陽極数より少ない場合においては、脱落の発生は検知できるが、場所の特定は不可能であった。想定要因としては、1,2個の犠牲陽極が脱落した場合でも、周囲の犠牲陽極がその部位の防食を維持するため、脱落に起因する電位変化が小さく、正確な脱落位置の特定に至らなかったことが考えられる。今回の実験条件においては、電位変化に基づき脱落の有無を検出することは可能であることがわかり、実際の管理上は、臨時でダイバーによる詳細検査を実施する基準と成り得ることが示された。脱落検知精度はグループ数に依存するため、管理上要求される精度に応じて、グループ分けや測定点数を決定するのが望ましい。




Figure 39 Deactivated anodes (Lack 1, Lack 2) in the numerical experiment




Figure 40 Calculated voltage distribution of the line 1 with 2 deactivated anodes at 11th year

4.5 実構造物における適用例

4.5.1 実験概要

本システムを実際の港湾施設に適用した結果を示す。2002 年に供用が開始された大井ふ頭ジャケットについて、まず0 年目から9 年目まではシステムモデルのみによる予測を行う。次に10 年目(2012 年)における電位測定結果から、観測モデルによる修正を行う。そして、20 年目までの電流量を再びシステムモデルにより予測する。Figure 41に示す測定ライン3 本に沿って電位を測定し、データ同化を行った。なお犠牲陽極No.1およびNo.2 にはシャント抵抗が取り付けられており、電流量の直接計測が可能である。犠牲陽極のグループ分けは、測定点の位置関係上、水平方向には均一と仮定して、水深方向に3 グループとした。




Figure 41 Voltage measurement lines and monitoring anodes

4.5.2 推定結果

犠牲陽極No.2 について、電流量の直接観測値、推定値をFigure 42に示す。電流量の計測は供用開始1 年経過後から始められ、6 年目まで直接観測値は4 年目で電流量が1 A 前後に低減しており、その後は1 A を少し下回る値で推移している。それに対して推定値は、電流量変化の大きい通電初期に観測更新を行っておらず、システムモデルのみによる予測値であるため、観測値と大きく離れてしまっている。しかし、10 年目に観測更新を行ったことで観測値とほぼ一致した。電流低減後の犠牲陽極電流量

の変化は，消耗による分極抵抗増加が支配的となり，比較的安定して推移することから，それ以降はシステムモデルによる予測の信頼性は高いと考えられる．電流発生量のばらつきが大きい通電初期は観測更新を毎年行うなど重点的にデータを蓄積し，その後は数年に一度の頻度で観測更新を行うことで，効率的に電流量をモニタリングすることが可能になると考えられる．




Figure 42 Estimated current by data assimilation, and directly measured value in the No.1 anode

4.6 まとめ

社会インフラの1つである大型海洋鋼構造物の電気防食状態の新たな予測手法として，データ同化を用いて現場の情報を蓄積し，より高精度な犠牲陽極電流量予測を行うシステムを開発した．具体的な取り組みは以下の通りである．

- (1) 技術的知見から次の時刻における電流量を予測するシステムモデル，予測値を現場の観測値を用いて修正する観測モデルを組み合わせることにより，現場の測定情報を反映した犠牲陽極電流量予測法を開発した．
- (2) 犠牲陽極電流量の経年変化を模擬して計算した電位分布値を用いてデータ同化の数値実験を行い，定期的な現場データ取り込みにより，高精度に犠牲陽極発生電流量の将来予測ができることを示した．
- (3) 犠牲陽極脱落時の検知性能について検証を行い，3 個以上の犠牲陽極が局所的に脱落した場合は，電位測定により脱落発生の有無および場所を特定可能であることを確認した．
- (4) 実際の港湾施設で測定された構造物周囲の電位計測値を用いて，データ同化により犠牲陽極発生電流量の予測を行い，実環境における本手法の有効性を示した．

第5章 深層学習を用いた点火コイル信号に基づくエンジン失火検知技術の開発

5.1 はじめに

本章では、支配方程式が不確定であるブラックボックス型システムに対する状態モニタリング手法として、機械学習を用いて点火コイル信号から自動車エンジンの失火を検出する方法について検討する。エンジンを高効率、低排気化するためには、リーン燃焼や EGR 燃焼等、燃焼限界ぎりぎりの状態で運転することが求められる。製品ライフタイムに渡りエンジンが性能を発揮するためには、エンジン劣化による燃焼不安定化や失火発生を精度良く検出する必要がある。しかし、追加センサーの搭載は車両コスト増加につながり実現が難しいため、既にエンジンに搭載されているコンポーネントとして、点火コイルの電圧電流信号の活用を検討する。

点火コイルは、空気と燃料の混合気を圧縮後に、点火プラグから火花放電を発生させるための高電圧を生成するデバイスである。エンジンは、日常運転時は毎分約 1200~3000 回転程度の領域で使用され、燃焼サイクルはエンジン 2 回転で 1 サイクルであるので、1 気筒当たり毎分約 600~1500 回の点火が行われる。点火コイルにより点火プラグ部に形成される放電路は、筒内流速や温度、圧力や点火プラグ電極間距離等によってその状態が変化し、その挙動が電圧電流信号に現れる。点火プラグ電極は燃焼ガスが直接接触するため、より直接的な情報を取り出すことが可能であると考えられている。しかし、放電路は流動ばらつきや点火プラグ表面状態などの影響を強く受け、放電路伸長や放電路再形成(リストライク)の挙動はサイクル毎に大きく変動する。その結果、電圧電流応答には流速、温度、圧力、電極表面抵抗の影響が複合的に表れ、単一特徴量の抽出および閾値判定処理では、サイクル毎の燃焼状態を精度良く検出することが困難であった。また、物理モデルを用いた演繹的推定手法の場合、物理モデルを用いたシミュレーション計算を大量に実施する必要がある。エンジンのあらゆる運転条件を網羅することは計算負荷の観点で困難である。そのため、点火コイル電圧電流に基づく燃焼診断は、サイクル平均データに基づく平均的な挙動評価や、ハードウェアの劣化診断にとどまっている。

本章では、確率論的に発生する事象を伴う、複数の物理現象が入り混じったデータの処理手段として深層学習の画像認識を適用し、点火コイルの電圧電流信号から帰納的に失火検出する手法を検討する。放電時の電圧電流挙動を画像として表現することで、放電特性の違いを明示的に示すことができ、かつ深層学習モデルが分類の際に着目した部位を画像上に直接表示させることで、説明性の向上が期待できる。

まずエンジンベンチにて、燃焼サイクルと失火サイクルで筒内圧に差が出ると想定される膨張行程に失火検知用のポスト点火を行い、点火コイル電圧電流を測定する。次に、深層学習の入力画像となる電圧電流の 2 次元頻度分布(放電ヒストグラム)を作成し、100 万枚以上の画像でトレーニングされた AlexNet モデルに、失火サイクルと燃焼サイクルの画像を教師あり学習させる。そして、検証用データセットを用いて分類精度(失火検知精度)を検証する。さらに、深層学習の説明性を向上させるために、学習モデルが画像を判定する際の放電ヒストグラム上の活性度分布を可視化し、深層学習の判断根拠となる放電特性を分析する。

5.2 ポスト点火による失火検知コンセプト

5.2.1 点火コイル構造および動作原理

Figure 43 に点火コイルの回路図を示す．点火コイルの入力は 3 端子(DC12V，点火信号，信号グラウンド)で ECU に接続される．DC12V は点火コイル内部の一次側コイルに通じており，一次側コイルの逆側端子は IGBT のコレクタに接続されている．また点火信号は IGBT のゲートに，信号グラウンドはエミッタに接続される．二次側コイルは一次側コイルと磁束を共有し，巻き数比は 100 程度に設定される．二次側コイルの片側端子は点火プラグの中央電極に，逆側端子はダイオードのアノード側へ接続され，ダイオードのカソード側は信号グラウンドに戻る．点火プラグの側方電極はエンジン本体と通電しており，グラウンドと接続される．ECU により点火信号が付加されると，IGBT のコレクタとエミッタが導通し，一次側コイルに電流が流れる．点火信号が終了すると，一次側コイルの電流が遮断され，磁界の変化に基づいて自己誘導効果により一次側コイルに電圧が生じる．そして相互誘導作用により，コイル二次側にも一次二次の巻数比に依存した電圧が発生する．二次電圧が点火プラグに付加されると，電極間で絶縁破壊が発生し，スパークが形成される．スパークにより混合気の着火を行うことで，エンジンの燃焼が開始される．電極間を流れた二次電流は，ダイオードを通り最終的に信号グラウンドに流れ込む．点火コイルの発生するエネルギーの大きさ E は，二次エネルギーとして式(103)で評価される． V は二次電圧， I は二次電流， T は放電期間である．

$$E = \int_0^T V I dt \quad (103)$$




Figure 43 Electric circuit of an ignition coil

5.2.2 ポスト点火による失火検知の概要

燃焼室内で失火が発生すると，当該サイクルでは筒内圧及び筒内温度が低下する．そこで，主点火を実施した後の膨張行程にポスト点火を行い，失火時に発生する筒内圧の低下を検知することを考える．

Figure 44 にエンジンの筒内圧と点火コイル信号の一例を示す．上段のグラフは失火時および燃焼時の

筒内圧を、中段のグラフは点火パルス信号と一次電流を示す。また下段のグラフは点火コイルの二次電圧および二次電流を表している。ECU から点火パルスが印加され主点火前の充電が行われる期間は、一次電流は徐々に上昇し、コイルに電荷が蓄えられる。点火パルスが OFF になると一次側の電流が遮断され、相互誘導によりコイル二次側に高電圧が発生する。容量放電により二次電圧が急激に増加し、グラフのマイナス方向へスパイク波形が現れる。その後、電極間に放電路が持続する誘導放電へ移行し、絶縁破壊直後をマイナス方向へのピークとして徐々に低減する二次電流が発生する。二次電流がゼロになると放電路が消滅し、放電期間が終了する。主点火により主燃焼が正常に行われると、筒内圧は上死点付近で上昇する。一方、失火が発生した場合、筒内圧は圧縮による小さな圧力ピークを示すのみとなるので、燃焼時と失火時では上死点以降の膨張行程において圧力差が発生する。ポスト点火の基本コンセプトは、このような圧力差を検出することである。

放電が発生する瞬間の電圧は絶縁破壊電圧 $V_{breakdown}$ と呼ばれ、式(104)で表されるように筒内圧力への依存性が高い¹⁹。p は筒内圧[bar]、 T_g は温度[K]、 d_{gap} は放電ギャップ距離[mm]である。

$$V_{breakdown} = 4.3 + 136 \frac{p}{T_g} + 324 \frac{p}{T_g} d_{gap} \quad (104)$$

また、絶縁破壊後の放電電圧 $V_{discharge}$ は下記の実験式(105)が知られている²⁰。I は二次電流、 l_{sp} は放電路長さである。

$$V_{discharge} = IR_{sp}(t) = 40.46 l_{sp} I^{-0.32} p^{0.51} \quad (105)$$

式(104)(105)に基づくと、絶縁破壊電圧および放電電圧は筒内圧と相関性が高く、絶縁破壊時及び放電中の電圧から筒内圧を推定することが可能であると考えられる。しかし、放電は筒内圧力や温度、ガス組成や点火プラグ周り流速等の複数因子が組み合わさり発生する非定常な現象であり、エンジン側の吸気量ばらつきや燃料噴射量ばらつき等にも影響され、電圧電流波形のサイクルばらつきが大きい。人間の知見に基づき定められる特徴量のみで失火時の電圧電流挙動を完全に把握することは困難と考えられ、リアルワールドでの様々な運転条件を想定した際に、失火検知率の低下が懸念される。また、エンジンが異なる場合や、燃料などの環境条件が異なる場合、または車両劣化等によっても、失火の判定閾値や、失火検知に有効な特徴量自体が変化してしまう可能性があり、膨大な適合作業が必要になる可能性がある。




Figure 44 Examples of the cylinder pressure and ignition coil signals

5.2.3 深層学習を用いた画像認識による失火検知コンセプト

点火コイル電圧電流波形から、人間の知見に依存せずに失火を検出でき、かつ環境変化や車両劣化に伴う特徴量の変化を自動で学習、更新することができれば、適合工数の大幅低減およびエンジンのライフタイム全期間に渡る性能保証が可能となる。そこで、深層学習を用いて点火コイル信号から特徴量を自動抽出し、失火サイクルと燃焼サイクルを分類するモデルを構築する。ただし、点火コイルを用いてエンジンの異常診断を行うという性質上、構築するモデルには分類の根拠として、放電現象と紐づいた説明性が求められる。本研究では、点火コイルの電圧電流時系列データを基に2次元ヒストグラム(以後、放電ヒストグラムと称する)を生成し、CNNを用いて画像を学習させ失火分類モデルを構築する。通常、時刻歴データを2次元画像として解析する際、周波数スペクトルが用いられる。例えば笠原らは、エンジン外部から計測した音圧データを用いて周波数解析を行い、ノッキング音の分離を行っている¹¹⁸。一方、本研究における点火コイル電圧電流信号の解析では、電圧値のオフセット量など、周波数解析では捉えにくい特徴量を取り扱う必要がある。そのため、時刻歴情報を削除した電圧電流の2次元画像を用いることとした。そして放電ヒストグラム上で学習モデルの活性度をマッピングすることで、電圧電流波形のどの部分に着目していたか、分類根拠を明らかにする。

Figure 45 に深層学習を用いた画像認識による失火検知フローを示す。まず、エンジン試験から燃焼時と失火時のエンジンサイクルデータ(筒内圧および点火コイル信号)を取得する。取得したデータの60%を学習用に、残りの40%を検証用に用いる。教師データとして用いる筒内圧センサーのピーク値に基づいて失火の有無を判定し、失火の場合は G01、燃焼の場合は G02 と、当該サイクルのグループ分

けを行う．ここで，点火コイル信号から放電ヒストグラムを生成し，入力を点火コイル放電ヒストグラム画像，出力を筒内圧センサーに基づき決定したグループ番号として，深層学習のモデル学習を行う．

機械学習の分類問題におけるモデルの精度は一般的に，検証用データ数に対して分類を正しく行えたデータ数の割合で評価される．この場合，仮に 100%の精度で分類を行えていたとしても，検証用データの中で，分類の確信度を表す分類スコアが高いものと低いものが混在してしまう．すると，機械学習が検証用データのどの部分に着目して判断を行ったかを分析する際に，全画像に共通する判断根拠を抽出することが困難となり，物理的に説明性のある結果を得にくくなる．

そこで，モデルの精度検証後に，検証用データセットから分類スコアが特定の基準以下(例えば 0.9)であった画像を抽出し，ノイズを付与した上で学習用画像群へ複製して学習を繰り返す，アクティブラーニングを導入した．アクティブラーニングは有用性の高いデータを選択し，学習データに追加して再学習を繰り返すことで，限られたデータ数でモデル精度を向上させるアプローチである¹¹⁹．本研究においては，検証用画像の分類スコアを再学習用画像の選択基準とし，選択された検証用画像の電流電圧波形および画像自体にノイズを付与した上で，再学習を行わせた．低分類スコア画像を複製した後の再学習では，学習用データセットにおける複製された画像の影響度が相対的に大きくなり，モデルは前回と同じ分類を行うと式(60)に示される誤差関数が増加してしまう．すると，モデルは低分類スコア画像と他の画像に共通する特徴量を抽出し，より誤差関数を低減する方向に学習を行うため，複製された画像を中心に，分類スコアを向上させることが可能となる．このプロセスを繰り返すことにより，学習モデルの判定の確信度を向上させる．そして，学習終了後のモデルを用いて，重要度の高い領域を放電ヒストグラム画像上に表示することで分類根拠を可視化する．




Figure 45 Flow of the image classification by Deep Neural Network

5.3 エンジン試験および DNN モデル構築

5.3.1 エンジン仕様および試験条件

4 気筒エンジンを用いて失火、燃焼条件における点火コイルデータを取得し、深層学習モデルによる失火分類モデルの構築について説明する。Table 8 に本検討に用いる多気筒エンジンの主要諸元を、Figure 46 にエンジン外観を示す。エンジンは量産型 1.6L 4 気筒エンジンをベースとしており、ボア/ストロークは 79.7/81.1，機械圧縮比は 10.5 である。燃料は RON100 ハイオクガソリンを燃料圧力 20MPa の DI 方式で供給した。点火コイルは、二次エネルギー 164mJ，二次電流ピーク 140mA，放電期間 2.6ms の試作コイルを用いた。点火プラグは筒内圧センサー体型の M12 サイズの J 型電極タイプであり、筒内圧センサーは Kistler 社製の 6052C を用いた。点火コイルの一次電流の計測には横河電機製の電流プローブ 701933(50MHz, 30Arms)，二次電流の計測には横河電機製 701917(50MHz, 5Arms)，電流プローブのアンプ電源として横河電機製 7019-34 を用いた。二次電圧の計測には、

Tektronix 社製の高電圧プローブ P6015A を用いた。また、二次電流および二次電圧の計測に必要な配線分岐は低抵抗(0.1Ω)ケーブルを用いて行い、点火コイル・点火プラグ直結型の量産エンジンと比較して、配線抵抗が増加しないよう考慮した。測定は第4気筒を対象に行い、筒内圧および点火コイルデータは、Keyence 製データロガーGR-7000 を用いてサンプリング周波数 1MHz で取得した。

Table 8 Engine specifications

Parameters	Specifications
Engine	In-line 4 cylinders
Displacement	1618cc
Bore $\times$ Stroke	79.7mm $\times$ 81.1mm
Stroke/Bore ratio	1.01
Compression ratio	10.5
Fuel	RON100 Gasoline
Fuel supply	Direct injection (Fuel pressure: 20MPa)
Ignition coil	Prototype coil (Peak Secondary current 140mA, Discharge duration 2.6ms, Secondary energy 164mJ in the engine-stop condition, Dwell time = 5.14ms, VB=14V)
Spark plug	M12 (Cylinder pressure integrated)




Figure 46 Multi cylinder research engine

Table 9 にエンジン試験条件を示す。本試験では失火発生を模擬して、エンジン回転数を 1400rpm に保持しながら ECU の燃料噴射パルス ON-OFF し、ファイアリング運転とモータリング運転を交互に実施しながら、両者が切替わるサイクルを含む連続約 57 サイクルのデータ計測を行った。ファイアリング時の空気過剰率は $\lambda=1.0$ 、冷却水温度およびオイル温度は 80°C に保持した。主点火時期は、NMEP 0.3MPa 運転時における ECU 指令値である -38deg.ATDC で固定し、主点火の Dwell time は供試コイ

ルの標準値である 5.14ms とした．なお，deg.ATDC は圧縮上死点を基準としたクランク角度を表しており，圧縮行程の上死点が 0deg.ATDC，マイナスの値の場合は上死点前，プラスの場合は上死点後を表す．

ポスト点火時期について，圧力の観点では燃焼時と失火時で圧力差が大きくなる膨張行程前半が望ましいが，上死点付近では主燃焼により引き起こされるガス流動の影響が電圧に現れ，燃焼時と失火時の公平な比較ができなくなる．また，膨張行程後半になると圧力差が小さくなり，電圧の圧力に対する感度が低減し，コイル信号からの検出が困難となる．主燃焼の影響について，今回の運転条件においては 40deg.ATDC 付近で熱発生が 100%に到達して燃焼が終了しており，それ以降であれば主燃焼による流動影響が排除できると考えられる．また膨張行程後半における圧力差については，予備試験を実施して上死点後 90deg.ATDC では 0.2MPa 程度の差圧が残っており，本コンセプトが適用可能であることを確認した．これらの予備検討結果に基づき，排気上死点後 50, 70, 90deg.ATDC にポスト点火を実施した．

ポスト点火の充電時間についても予備試験を行い，適正化を行った．充電時間は長すぎると点火コイルに蓄えられるエネルギーが大きくなり放電路が安定してしまい，筒内圧変化に対する感度が低減した．また，充電時間が短すぎると放電路が安定せず，絶縁破壊発生後に，容量放電から誘導放電への移行に失敗し，放電路が消滅してしまった．これらの結果より，ポスト点火の充電時間は放電が成立する範囲で可能な限り小さい値として，充電時間は 0.75ms とした．なお，放電成立可否は筒内圧にも依存性があるため，ポスト点火時期とポスト点火充電時間はセットで適正化する必要がある．

モータリングからファイアリングへの移行，およびファイアリングからモータリングへの移行をそれぞれ 3 回ずつ計測し，合計で 1017 サイクルのデータを取得した．取得したデータは，深層学習モデルの学習用に 619 サイクル(失火 311，燃焼 308)，モデル精度検証用に 398 サイクル(失火 209，燃焼 189)を用いた．

Table 9 Engine test conditions

Parameter	Value
Engine rotation speed	1400 rpm
Engine load (NMEP)	0 (Motoring) → 0.3MPa 0.3MPa → 0 (Motoring)
Air excess ratio (λ)	1.0
Coolant temperature	80°C
Oil temperature	80°C
Spark timing (Main)	-38deg.ATDC
Charge time (Main)	5.14 ms
Spark timing (Post)	50, 70, 90 deg.ATDC
Charge time (Post)	0.75ms
Number of cycles (For training)	619 (Misfire:311, Combustion:308)
Number of cycles (For validation)	398 (Misfire:209, Combustion:189)

5.3.2 深層学習の入力画像の生成

Figure 47 に失火サイクル (G01, 1400 rpm Motoring) と燃焼サイクル (G02, 1400 rpm NMEP0.3MPa, $\lambda=1.0$) における, 筒内圧および点火コイルの二次電流と二次電圧の波形を示す. グラフ上段は筒内圧 (赤) と, 筒内圧から式(106)で算出される熱発生率を当該サイクルの総熱発生量で除した熱発生割合 (緑) である. ここで, dQ は熱発生率, p は筒内圧, V は筒内容積である, κ は比熱比であり θ はクランク角である.

$$dQ(\theta) = \frac{1}{\kappa(\theta) - 1} (V(\theta)dp + \kappa(\theta) \cdot p(\theta)dV) \quad (106)$$

G01 は失火サイクルを示しており, グラフ上段に示される筒内圧は上死点(0deg.ATDC)でピーク値約 0.8MPa に到達する. G02 は燃焼サイクルを示しており, 筒内圧は 15deg.ATDC 付近でピーク値約 2.4MPa に到達する. 試験用エンジンは筒内圧センサーを搭載しているため, 筒内圧センサーのピーク値を参照することで失火と燃焼サイクルを判別することが可能である.

グラフ中段は二次電流, 下段は二次電圧を示している. 二次電圧を見ると, -80deg.ATDC 付近で値がゼロからプラス側にやや上昇している. これは, 主点火時期-38deg.ATDC までに充電を完了するために, 事前に点火コイルへの充電が行われていることを示している. 点火時期となり一次電流が遮断されると, 磁界変化に起因した自己誘導効果により一次電圧が発生し, 同時にコイルを介した相互誘導作用により二次電圧が発生し, 点火プラグ電極間の絶縁が破壊されて放電路が形成される. この時, 二次電圧にはスパイク状の波形がマイナス方向に発生し, そのピーク値は-5kV に達する. 絶縁破壊後には放電路が形成され二次電流が流れ始める. 二次電流は絶縁破壊直後にマイナス方向のピーク値約-140mA に達し, 放電期間中はゼロに向かってほぼ直線的に低減し, 逆三角形の電流波形となる. 放電期間中の二次電圧は-1~2kV の範囲を取りながら推移し, 点火コイル内のエネルギー放出が完了して二次電流がゼロになった時点で放電終了となり, 二次電圧はコイルの残荷をアースに向け放出しながらゼロに収束する.

主点火終了後のクランク角 70deg.ATDC 付近では, 失火検知用のポスト点火を実施している. ポスト点火では放電路が形成される最小限の放電を行えるよう充電を行っており, 電流波形は主点火時の波形を相似縮小した形となる. 主点火時は失火, 燃焼の両条件で筒内圧はほぼ同一であるのに対して, ポスト点火を行う 70deg.ATDC 付近では, 筒内圧が失火有無条件で異なる様子が見られる. 点火コイル二次電流と二次電圧を深層学習を用いて解析し, 有望な特徴を特定する.




Figure 47 Cylinder pressure and coil secondary signals(Left : G01 1400 rpm, Motoring, Right : G02 1400 rpm, NMEP 0.3 MPa, $\lambda = 1.0$).

点火コイルの電圧電流の時系列データは、絶縁破壊が発生する約 0.005~0.01ms の間に値が大きく変化する一方、放電期間は時間オーダーが 1000 倍以上長い 2~3ms に及ぶ。電圧電流の時系列波形を、放電期間全体を捉えるような時間レンジでプロットを行うと、絶縁破壊時の波形が時間軸方向につぶれてしまい、電圧電流の変化挙動を可視化することが困難である。そこで時間軸情報を削除し、横軸を電圧、縦軸を電流とした 2 次元平面へ情報を圧縮し、電圧電流プロットとして放電波形を表現することとした。

電流と電圧の時系列データから時間軸情報を削除して 2 次元平面上で表現することは、**Figure 18** に示される、金属の腐食挙動を示す分極曲線測定でも使用される表現方法である。分極曲線測定の場合は、電流と電圧の関係から金属のインピーダンスを求めており、時間軸情報は冗長になるために排除される。類似の事例として、リチウムイオン電池の劣化度合いを表すコールコールプロットも、時間軸情報を削除した 2 次元複素数平面への電圧電流の可視化が行われる。このような 2 次元平面への可視化は、システムの特性を視覚的に捉えることができる点が利点であると考えられる。本研究においては、

時間スケールの異なる現象である絶縁破壊と誘導放電の同一平面上への可視化，および深層学習の判断根拠の視認性向上のために，点火コイルの電圧電流時系列データを2次元平面へプロット変換を行う．

Figure 48 にポスト点火時実施時における，電圧電流の時系列データを用いた放電ヒストグラム生成プロセスを示す．上段が失火サイクル(G01)，下段が失火サイクル(G02)のデータを示している．まず，ポスト点火時の点火コイル二次電流と二次電圧の時系列データを図左側のように取得する．次に図中央に示す通り，電圧を横軸，電流を縦軸とした平面プロットを行う．平面上の各点は，サンプリング周波数 1MHz で計測した測定点に対応しており，ポスト点火の充電開始 300 サンプル前から放電終了 300 サンプル後までプロットを行った．各サンプリング点のプロットの色については，当該サンプルと前サンプルの電圧変化量に応じて，プロットの色を変えて表示している．青いプロットは，1 サンプリング時間中における電圧変化が大きい点を示しており，付近の点との間隔も広い．赤およびピンク色は電圧変化量が小さい点であり，点同士の間隔が狭く重なって表示される．

失火サイクルを示した G01 を例に，電圧電流プロット上における放電挙動を説明する．ポスト点火の充電開始直前は，二次電流はゼロ，二次電圧は主点火における残電荷により $-1.0 \sim -0.5 \text{ kV}$ 前後を示し，平面上で右上に位置する点群が初期点となる．充電のための一次電流通電中は，二次電流は引き続きゼロで，二次電圧はややプラス方向に遷移する．そして一次電流が遮断されると，相互誘導によりコイル二次側に電圧が発生し，プロットはグラフ左側へ急速に遷移して二次電圧のピーク値は約 -4 kV に達する．二次電圧の変化と同期して絶縁破壊により二次電流が流れ始め，二次電流のマイナス側ピーク時において -28 mA 程度を示す．このような，電圧電流プロット右上から中央左側に遷移するプロット部分が，容量放電の挙動である．

次に，プロットは二次電圧 -1 kV ，二次電流 -50 mA 付近へ遷移し，安定した放電路が形成される誘導放電に移行する．容量放電から誘導放電への移行はプロット 1 点の間に発生しているが，これは今回のサンプリングレート 1MHz が，絶縁破壊による電気回路形成の時間スケールに比べて長いため，過渡変化を十分な時間分解能で計測できていないことに起因すると考えられる．

誘導放電移行後は，二次エネルギーを放出しながら電圧電流が低下していくため，二次電流および二次電圧がゼロに近づく右上方向にプロットが遷移する．途中で放電路の伸長やリストライクが発生すると，二次電圧が単発的にマイナス側に振れるため，プロットの軌跡に段差や不連続面が生じる．最終的に二次電流がゼロになり，二次電圧に残電圧が残った状態で放電が終了する．

燃焼サイクル G02 については，充電中のプロットは，二次電流ゼロ，二次電圧 0.25 kV 付近に表れる．このプロットは，失火時に比べて二次電圧が高い側へオフセットした位置に現れるが，これは燃焼が成功したサイクルでは，主点火後の高い筒内圧で点火コイルの二次エネルギー放出が促進され，失火サイクルに比べてマイナス方向の残電圧が減少するためと考えられる．ただし，燃焼サイクルの燃焼圧挙動は毎サイクル変動し，ポスト点火の充電開始時における二次電圧値のオフセット量も変動するため，この指標のみでは失火サイクルを高精度に判定することは困難である．誘導放電への移行後の波形についても，失火時と燃焼時で若干の形状差異が見受けられるが，サイクル毎での放電挙動バラつきも大きく，全サイクルデータに適用可能な失火時の電圧電流変化の普遍的特徴量を目視で抽出することは困難であると考えられる．


次に，深層学習を用いて電圧電流プロットから失火を高精度に検出することを検討する．画像認識の際，重複するプロットは認識されないため，解像度のダウングレードを行った．図右側に，深層学習の

認識性を高めることを目的として、点火コイルの電圧電流挙動を 2 次元ヒストグラム画像化した結果を示す。放電ヒストグラムは縦横をそれぞれ 100 分割したメッシュ状の領域画像となっており、横軸が二次電圧、縦軸が二次電流に対応している。あるデータをプロットする際、電圧電流値に基づいてそのデータが属するメッシュ座標を決定し、当該メッシュの輝度を 1 増加させる。すると、電圧電流プロットにおけるデータ点の重なりを、放電ヒストグラム上におけるメッシュの輝度として表現することが可能となる。また、画像データの解像度を削減することで計算負荷も軽減させることが可能となる。

今回の放電ヒストグラム画像では、1 枚当たり約 2000 データをプロットしており、輝度積算回数が多い場所は輝度 100 以上、逆に 1 回しかプロットされない領域の輝度は 1 となり、そのままヒストグラム画像を生成すると輝度 1 の領域の可視性が低下しまい、目視による最終的なメカニズム分析の際に支障が生じる。そこで、輝度 1 の領域の可視性を向上させるために、輝度カウントの上限を 10 とし、10 回以上同じ領域のプロットが行われる場合も、輝度は 10 として画像を生成した。本操作は可視化時の工夫としてなされたものであり、深層学習による失火と燃焼の分類精度には影響がないことを確認している。

失火サイクル G01 の右側、二次電圧・二次電流の放電ヒストグラムでは、充電前、充電中は電圧電流変化がないため同一のメッシュ上に輝度が積算され、輝度が高い赤点として表示される。絶縁破壊時のマイナス方向およびプラス方向ハンチング挙動は、電圧電流変化が大きく同じメッシュに 1 回しか輝度がカウントとされないため、輝度が低く青白い領域として表示される。放電路が安定する放電期間中は電圧変化が小さく、同じメッシュ状の輝度積算数が増加し、黄色や赤で表示される。このように、前述の 2 次元プロットと同じ情報量を保持した放電ヒストグラム画像を生成することで、計算負荷の軽減と深層学習での認識性の向上を図った。

G01 Misfire



G02 Combustion




Figure 48 Generation processes of the discharge histogram from time series voltage and current

5.3.3 DNN モデル構築

Figure 49 に畳み込みニューラルネットワークの構造の一例を示す。畳み込みニューラルネットワークは、人の視覚をモデルに考案されたニューラルネットワーク構造で画像認識にて高い精度を発揮する。本研究では、数値計算ソフトウェア MATLAB® の Deep Learning Toolbox に実装されている畳み込みニューラルネットワークとして、100 万枚以上の画像でトレーニングされた学習済みモデル AlexNet を使用した。

ここでは入力画像を 6×6 の行列として、入力層(Input)を構成する。次に畳み込み層(Convolution)により、入力画像に対してフィルタまたはカーネルと呼ばれる 3×3 の行列を掛け、画像から特徴を抽出する。フィルタは複数種類用意され、本研究では 20 種類のフィルタを用いている。続く活性化層(ReLU)では、入力値が 0 以下の場合には 0、0 より大きい場合は入力値をそのまま出力する活性化関数による演算を行う。次の最大プーリング層(MaxPooling)では、 2×2 等で区切った小行列の中の最大値を求め、

小行列を 1×1 に縮小した上でその最大値を格納する．図中に，入力画像と，1 回目の畳み込み層と ReLU 層の出力，畳み込み層 3，5 回目の出力の一例を示した．解像度を低下させながら，特徴が強調された画像を順次生成していることがわかる．

AlexNet における入力画像は 227×227 であり，このような畳み込み操作を計 5 回実施している．フラット層(Flat)では各画像のセル値を縦一列に並べ，機械学習の入力とする．以降は通常の機械学習の手順で出力データを得ることになるが，深層学習はネットワーク規模が複雑であり，モデルの自由度が高い．そのため教師データに対して過度にモデルがフィットしてしまい，学習範囲外のデータに対するロバスト性が低下する，過学習という現象が課題となる．そこで，ドロップアウト層(Dropout)を設け，フラット層からの入力信号を一定割合でランダムに遮断する操作を行う．すると，モデルの教師データへの依存性が下がり，よりロバストな結果を得ることが可能となる．最後に，全結合層で出力すべきパラメータにノードを絞り込み，G01 と G02 それぞれに相当するノードに出力されるスコアに基づいて，分類結果を決定する．このように，畳み込みニューラルネットワークでは，入力画像から自動的に機械学習の特徴量を設定することで，入力データに人間が加工をすることなく，学習を行うことが可能となる．モデルのパラメータとして，カーネルサイズは 3×3 ，エポック数は 50 とした．学習 5 回ごとに精度検証を 1 回行い，モデル精度を評価した．ドロップアウト操作確率は 0.2 とした．

深層学習の分類問題では，分類自体は正解していても，全結合層の出力値であり，判断の確度指標となる分類スコアが低い画像が多く存在する場合がある．分類スコアが低い画像が多いと，次ステップで分類根拠を可視化する際の信頼度が低下してしまう．そこで分類スコアの底上げのために，1 度目の学習終了後，検証用画像の分類スコアを個別に評価し，0.9 以下であった画像について，ノイズを付与した上で，学習用画像へコピーし，再度モデル学習を実施する構成とした．これにより，1 度目に誤判定した，もしくは分類スコアの低い画像が，第 2 回目の学習時により高い重みとして学習されることで，誤判定を起こした際の判断根拠となった特徴量の重要度が低減する．その結果，各画像に共通して観測される特徴量が残るように他の特徴量が排除され，モデルはよりロバストに失火判定を行うことができるようになる．今回は，学習とスコア評価を 10 回繰り返させた．




Figure 49 Relationship between an input image and the classification output

5.4 検証結果および判断根拠の可視化

5.4.1 モデル構築結果および検証精度

Table 10 に深層学習による判定結果を示す．検証データに用いた 398 サイクルのうち、209 サイクルは実際に失火、199 サイクルは実際に燃焼した．DNN モデルは、実際に失火した 209 サイクル中 208 サイクルを失火と分類することができたが、1 サイクルは燃焼と誤分類された．実際に燃焼した 189 サイクルについては、188 サイクルを燃焼として分類することができ、1 サイクルは失火と誤分類された．分類精度は 99.5% であり、失火 2 サイクルと燃焼 1 サイクルについては分類スコアが 0.9 に届かなかった．しかし、残りの 395 サイクルは 0.95 以上の分類スコアを示しており、分類操作の確信度は十分に高めることができたと考えられる．この学習済みモデルを用いて、判定根拠を可視化することにした．

Table 10 DNN classification result

Real class	DNN classification	Number of cycles
Misfire	Misfire	208
Misfire	Combustion	1
Combustion	Misfire	1
Combustion	Combustion	188
Total		398
Classification accuracy		99.5 [%]

5.4.2 深層学習の判定根拠の可視化

深層学習の判断根拠の分析方法としては、学習済みモデルに検証用画像を判定させ、画像の各部位の重要度をランク付けしてオリジナル画像上に重ね表示する手法が知られている．本研究では、分類モデルを回帰木等の単純なモデルで近似し、入力画像の特徴の重要度の可視化を行う **imageLIME** 法を採用した．**Figure 50** に失火時の判断根拠の可視化結果を代表的な 3 サイクルについて示した結果を示す．

Figure 51 にも同様に、燃焼時における判断根拠の可視化結果を示す．左側の画像が深層学習の入力に用いた放電ヒストグラム画像で、右側の画像は学習済みのモデルを用いて当該画像の重要度をカラーマップ化して入力画像に重ね、重要度の上位 4 領域のみを抽出したものである．ここで示される領域が、失火燃焼の判定に大きく寄与する特徴量になり得ると考えられる．抽出される領域はサイクル毎に異なるものの、放電ヒストグラム上で電圧電流がプロットされている部位を含んでおり、放電挙動に基づいて分類判断を行っていることが確認できる．

失火と燃焼サイクルで共通して抽出された放電ヒストグラム上の特徴として、(a)に示す放電期間中の盤から後半が抽出された．放電期間中は、二次電流は 0 に向かいプロットは上方に遷移するが、その際の電圧変化量の違いにより、放電ヒストグラム上のプロットに勾配が表れる．失火時は、二次電圧がゼロに向かう方向に変化し、プロットの勾配は鉛直に対して時計回りに $5\sim7^\circ$ ($111\sim156$ [A/V]) 程度傾斜している．これに対して、燃焼時は二次電圧変化が少なく、プロットの勾配は 0° から、二次電圧がマイナ

ス方向へ変化する方向の $-1 \sim -2^\circ (-22 \sim -44 [A/V])$ を示した。これは、筒内圧に依存する点火コイルのエネルギー放出挙動の違いに起因するものと推定される。

さらに、失火時の放電期間中のプロット群は、燃焼時に比べてより画像の右側に寄って存在していることが確認できる。失火時は筒内圧が低いため、放電中の二次電圧変化量が小さく、よりゼロに近い右方に位置したためと考えられる。なお、深層学習の画像認識は、特徴となる形状が画像中の異なる位置にあっても、同じ物体として認識する特性があるため、電圧平均値の違いによるプロットの全体的なシフトを特徴として捉えることが難しい。そこで今回は、追加で(b)で示す電圧電流がゼロの点を全サイクルでプロットさせて画像中に座標の基準点を作成しており、画像中におけるプロット群の位置を考慮できるようにした。一方で、図の左側におけるブレークダウンや上方における放電終了付近のプロットは、特徴領域として抽出されなかった。これらの電圧電流挙動はサイクル毎の再現性が低く、特徴量から排除されたと考えられる。

上記の議論を一般化するために、全サイクルの平均的挙動の観察を行った。**Figure 52**は、重要度上位4位までを抽出した画像を、検証用の画像全サイクル分で合算した画像である。緑色の領域は失火時の、ピンク色の領域は燃焼時の特徴量領域を示しており、白色の領域は両者が重複していることを示している。まず、失火と燃焼の境界部には必ず白の重複領域が挟まっており、単一特徴量での閾値判定では、高精度な分離が難しいことが読み取れる。

失火時の特徴量領域は、放電期間の前半～後半にかけて、二次電圧がゼロに近い右側に位置する。また領域の横幅が狭いことから、プロットが生成される位置の再現性が高い傾向があることが読み取れる。逆に、燃焼時の特徴量領域は横幅が広く、ヒストグラム上方ほど拡大する傾向がある。これは燃焼時には放電期間後半には部分的に燃焼が開始しており、二次電圧に初期燃焼のばらつきの影響が表れているためと考えられる。さらに、燃焼時は右上にピンク色の切り離された特徴量領域が存在している。これは燃焼サイクルでは高筒内圧により主点火におけるエネルギー放出が促進されるため、ポスト点火開始時まで残留している電荷が少なく、二次電圧がゼロに近い図右側にプロットされやすいためと考えられる。

両者が重複する白い領域については、放電開始直後である特徴量領域の下側では、横幅一帯がほぼ重複しているが、放電期間の中盤から後半にかけては白い領域が細くなっており、失火と燃焼の分離がしやすいことを示唆している。そして、放電期間の終了時には白い領域が横方向に大きく広がり、再び失火と燃焼の分離を困難にしている。このように、失火と燃焼を分類するための特徴量領域は放電期間中に場所や広さが変動している。失火と燃焼を高精度に判別するには、放電ヒストグラム上にて、放電期間中盤から後半のプロット勾配および位置に着目することが望ましいとの指針が得られる。




Figure 50 Visualization of the judgement basis (G01, Misfire case)




Figure 51 Visualization of the judgement basis (G02, Combustion case)




Figure 52 Important feature zones for the misfire and combustion classification (Cycle-averaged).

5.4.3 抽出された特徴量に対するメカニズム解析

DNN から得られた判定根拠を検証するため、抽出された特徴量に対する物理的なメカニズムを分析した。放電ヒストグラム上での勾配に違いがみられるということは、電流と電圧の相対関係が変化していると考えられる。Figure 53 は二次電流と二次電圧について、失火および燃焼 3 サイクルずつを重ねて比較した結果である。青線が失火サイクル、赤線が燃焼サイクルを示している。

二次電流については、失火時と燃焼時で放電期間の中盤から後半に違いが表れており、放電開始から同じタイミングにおける電流値に最小で ΔI の差が見られた。また、二次電流がゼロとなるタイミングについても、最小で ΔT_d の差分があった。これは、失火サイクルにおいては燃焼サイクルよりも放電期間が長くなる傾向があることを示している。

二次電圧については、主燃焼の有無に起因する筒内圧の違い ΔV_1 を、ポスト放電に向けた充電中の二次電圧から検出できる。しかし、主燃焼による圧力差は運転条件によって変化することから、 ΔV_1 を所定の値に定めることは困難と考えられるため、検討から除外した。ポスト放電の放電開始から同じタイミングにおける二次電圧については、二次電流同様に差分 ΔV_2 がみられる。これは、失火時は二次電圧がマイナス方向に伸びにくくなっていることを示している。

これら 2 つのデータに基づくと、次のようなメカニズムが考えられる。失火時は燃焼時に比べて筒内圧が低く、放電電圧が小さくなる。その結果、式(103)で表される二次エネルギーの放出速度が遅くなり、二次電流がゼロに低減する速度が低下し、放電時間が長くなる。この現象が、 ΔI 、 ΔT_d 、 ΔV_2 の要因となっていると考えられる。

各パラメータについて、単体でも失火時と燃焼時で差分がみられるが、同じ失火でもサイクルばらつきが存在し、その振幅は失火時と燃焼時の差分に匹敵する。そのため、単体パラメータの閾値や判定タイミングを決定することは困難であると考えられる。また、電流と電圧の変化は、オームの法則に基づき互いに値が規定されるため、今回のように時間情報を削除した 2 次元平面に投影することで、2 パラメータの相互作用を鑑みて、両者の持つ情報を有効活用することが可能になると考えられる。

本論文で開発した DNN モデルは、与えられた放電画像をすべて考慮し、電圧ハンチングなどのロバストでない特徴を除外しながら、有望な特徴を抜け漏れなく抽出することが可能である。また、画像に基づく診断手法は、点火コイルの放電波形に限られず、あらゆるコンポーネント信号を解析できるため、様々な製品に適用可能である。また、深層学習の寄与度可視化するプロセスは、コンポーネントのドメイン知識を必要とすることなく特徴量を調査することができ、モニタリング手法の初期検討に適していると考えられる。

一方で、機械学習に基づくアプローチは、学習させたデータの範囲内では有効性が担保されるが、未知の放電挙動に対応ができない。本技術を実用化するためには、実車で点火コイルの信号を継続的にモニタリングしつつ、様々なユースケースを網羅して学習させるか、複数の同型車の学習結果を転移学習を用いて蓄積し、モデルを OTA で逐次、アップデートすることが考えられる。

将来応用としては、深層学習モデルの分類クラスを細分化するか、燃焼期間などのスカラー値を直接予測する等して、リーン運転や EGR 運転等の燃焼限界に近い運転モードでの燃焼不安定性検出を行うことが考えられる。




Figure 53 Comparisons of secondary current and secondary voltage for the misfire and combustion cycles

5.5 まとめ

環境負荷の高い工業製品の1つである自動車について、予防保全および異常早期発見に向けたモニタリング技術への関心が高まっている。本章では既存のエンジン部品を活用した燃焼診断技術として、機械学習を用いて点火コイル信号からエンジンの失火を検出する方法を検討した。具体的な取り組みは以下の通りである。

- (1) エンジン膨張行程にポスト点火を行い、点火コイル電圧電流から筒内圧を推定し、失火を検出するコンセプトを検討した。
- (2) 流速、温度、圧力、電極表面抵抗の影響が複合的に表れる点火コイルの電圧電流応答から、失火に関する特徴量を網羅的に抽出する手法として、深層学習による画像認識を適用した。
- (3) エンジンベンチ試験にて、失火状態および燃焼状態における点火コイル電圧電流を測定し、深層学習入力用画像として電圧電流の2次元ヒストグラムを生成した。
- (4) 畳み込みニューラルネットワークとアクティブラーニングを用いた失火分類モデルを構築し、分類精度 99.5%を確認した。
- (5) 深層学習モデルが画像を分類する際の、放電ヒストグラム上の活性度分布を可視化し、深層学習の判断根拠となる放電特性を抽出した。
- (6) 失火と燃焼を高精度に判別するには、放電ヒストグラム上にて、放電期間中盤から後半のプロット勾配および位置に着目することが望ましいとの指針が得られた。これは、筒内圧力差に起因する二次エネルギーの放出速度の違いにより引き起こされると推定される。

第6章 結論

6.1 各章のまとめ

本研究では、実問題の不確定性を考慮した間接モニタリング手法を検討した。各章の結論を以下にまとめる。

第1章 緒論

実問題として海洋鋼構造物の防食状態およびエンジンの燃焼状態について、限られた観測量から間接的に対象物の内部状態をモニタリングする技術確立が必要である。しかし実問題には不確定性が含まれるため、システムの持つ不確定性の種類に応じて演繹的モデル、帰納的モデルを利用するアプローチが有効である。そこで本研究の目的を、海洋鋼構造物の防食状態およびエンジンの燃焼状態に対して、それぞれの不確定性を考慮した間接モニタリング技術を開発することとした。

第2章 従来研究

本研究の基礎事項であるデータ同化と機械学習の概要、また従来研究として、海洋構造物の電気防食状態と自動車エンジンの燃焼状態のモニタリング技術についてまとめた。加えて、従来技術の問題点について整理した。

第3章 ベイズ推定を用いた海洋鋼構造物の犠牲陽極発生電流量同定法の開発

大型海洋鋼構造物の電気防食状態を間接的にモニタリングする手法として、海洋鋼構造物周辺における海水中の電位測定データから犠牲陽極からの発生電流量および構造物表面電位を推定する手法を開発した。これらの測定量および推定量の関係は静電場の支配方程式であるラプラス方程式によって演繹的にモデル化し、有限要素法で離散化することにより実問題の幾何的情報を取り込んだ。また、境界条件の不確定性を多自由度の確率変数として取り扱い、モデルの柔軟性を向上させた。さらに、対象物の電気化学的な知見を先験情報としてベイズ推定の枠組みに取り込むことにより問題の悪条件性を克服した。最後に、実際の港湾施設に対して実証実験を実施して手法の有効性を検証した。

第4章 データ同化を用いた犠牲陽極電流量予測システムの開発

3章で開発した技術を基にデータ同化手法を適用し、時間方向に観測量と推定量の拡張を行った。犠牲陽極の消耗の電気化学的な振る舞いを、不確定性を含む時間発展の数理モデルとして表現し、経時的な現場データを蓄積することで、犠牲陽極の発生電流量の将来予測の精度向上を確認した。数値シミュレーションにより生成した模擬測定データを用いて、本手法の有効性を検証した。

第5章 深層学習を用いた点火コイル信号に基づくエンジン失火検知技術の開発

環境負荷の高い工業製品の1つである自動車について、予防保全および異常早期発見に向けたモニタリング技術への関心が高まっている。本章では、実際の自動車エンジンから簡便に取得できる点火コイルの電流電圧信号からエンジンの燃焼・失火状態を検出する技術を開発した。本問題においては点火コイルの電流電圧とエンジン内部の燃焼・失火状態との関係が複雑性と不確定性の高い放電現象によって

影響されている。この関係が未解明であることを考慮し、放電現象における電流電圧と燃焼・失火状態の間の物理的メカニズムを解明するために、機械学習を活用した。検出精度を向上するために、膨張行程における診断用ポスト点火時の信号を用い、さらに2次元画像情報に親和性のある畳み込みニューラルネットワークに電流電圧信号の位相面画像を入力することを提案した。エンジンから得られた実データを用いて畳み込みニューラルネットワークを学習し、画像分類時の判断根拠となる放電特性を位相面画像上に可視化した。この結果から放電現象に基づく物理的メカニズムを検討し、特に点火コイルの二次エネルギー放出速度が燃焼・失火状態のロバストな指標である可能性を見出した。

6.2 今後の課題

第3章~第5章について、今後の課題を以下にまとめる。

第3章 ベイズ推定を用いた海洋鋼構造物の犠牲陽極発生電流量同定法の開発

第3章では、犠牲陽極発生電流量同定コンセプトの提案および実際の港湾施設における実証試験を行い、提案手法の検査技術としての有効性を示した。残課題として、測定位置誤差の軽減および事前情報に用いる水槽試験データの精度向上が挙げられる。

測定位置誤差について、本論文では電位測定における電極位置は既知として取り扱い、観測モデル中の観測ノイズに位置ずれ $\pm 50\text{cm}$ を想定した値を入れて解析を行っていた。斎藤らは本研究を発展させる形で改善策を検討し、複数の参照電極を剛体に固定して、電極間の相対位置関係を保ちながら海中に投下することで、海中の電極位置と犠牲陽極の発生電流量を同時に推定する手法を開発した¹²⁰。

事前情報に用いる水槽試験データについては、現状は天然海水を用いた水槽試験を用いて、石灰質被膜付着を模擬した鋼材試験片から分極曲線を取得し、現場で測定された電位域で線形近似して分極抵抗を求めている。しかし、実環境においては海水温度や成分等が変化することが想定され、鋼材の表面状態は水槽試験と同様にならないと考えられる。今後、このような水槽試験と現実世界の乖離をデータサイエンス技術を活用して低減していくことが望ましい。異なる海水環境で運用される複数の海洋構造物データを用いて機械学習を行い、環境違い時における分極抵抗補正モデルを構築することで、さらなる予測精度の改善が期待できると考えられる。

第4章 データ同化を用いた犠牲陽極電流量予測システムの開発

第4章では、大型海洋鋼構造物の電気防食状態の新たな予測手法として、データ同化を用いて現場の情報を蓄積し、より高精度な犠牲陽極電流量予測を行うシステムを開発した。今後の課題として、最新の測定値を用いたモデルのアップデートが挙げられる。今後、水中無人観測器やクランプ式電流プローブを用いて、今まで測定されていなかった犠牲陽極の電流値が得られる等、不定期に測定データが得られる可能性がある。その際に、測定値情報をモデルに取り込み有効活用できるような、柔軟性を持たせることが、必要になると考えられる。

第5章 深層学習を用いた点火コイル信号に基づくエンジン失火検知技術の開発

第5章では、既存のエンジン部品を活用した燃焼診断技術として、機械学習を用いた点火コイル信号に

基づく失火検知を検討し、エンジンベンチで原理検証を行った。機械学習に基づくアプローチは、学習させたデータの範囲内では有効性が担保されるが、未知の放電挙動に対応できない。本技術を実用化するためには、実車で点火コイルの信号を継続的にモニタリングしつつ、様々なユースケースを網羅して学習させるか、複数の同型車の学習結果を転移学習を用いて蓄積し、モデルを OTA で逐次、アップデートすることが考えられる。将来応用としては、深層学習モデルの分類クラスを細分化するか、燃焼期間などのスカラー値を直接予測する等して、リーン運転や EGR 運転等の失火限界に近い運転モードでの燃焼不安定性検出を行うことが考えられる。

6.3 本研究で構築した間接モニタリング技術と今後の展望

Figure 54 に本研究で開発した間接モニタリング技術の概念図を示す。本研究では不確定因子を含む系に対する間接モニタリング技術を、ホワイトボックス型システムに分類される海洋鋼構造物の電気防食状態モニタリングと、ブラックボックス型システムに分類される自動車エンジン燃焼モニタリングを対象として開発した。海洋鋼構造物に対しては、海洋環境を表現可能な高自由度モデリング、先験情報を積極的に利用したベイズ推定、そして時間軸情報を蓄積/活用するデータ同化により、実環境のパラメータ不確定性に対応する物理モデリングおよび逆解析技術を構築した。エンジンに対しては、位相面を用いた現象の上位概念化、判断根拠を説明可能な深層学習モデル構築により、複合現象の本質に迫り、可視化する技術を構築した。また、複合現象の挙動可視化は、現象の演繹的解釈を支援し、ブラックボックスをホワイトボックスに変えることにも貢献できると考えられる。

本研究で扱った海洋鋼構造物は、電場解析の観点ではホワイトボックス型システムであるが、鋼材表面の分極抵抗が経時変化するプロセスは支配方程式が明確でなく、一部ブラックボックスを含んでいると考えられる。同様にエンジンも、放電現象の観点ではブラックボックス型システムであるが、支配因子の一員である筒内流速等は解析的に予測が可能であり、ホワイトボックスを一部含んでいると考えられる。このように、実世界では支配方程式が既知のシステム(ホワイトボックス)と、未知のシステム(ブラックボックス)が混在することが想定される。今後の展望として、間接モニタリング技術を本研究で扱った分野以外へ展開していくことが考えられる。その際、間接モニタリング対象における演繹的理解を進めるためには、初期状態でホワイトボックスとブラックボックスのどちらが支配的であるかによってアプローチを使い分けることが必要になると考えられる。




Figure 54 Developed indirect monitoring technology in this dissertation

付録 1：海洋構造物における犠牲陽極脱落パターン推定手法の提案

7.1 本章の目的

大型海洋構造物では多数の犠牲陽極により防食状態が保たれているが、一部の犠牲陽極の異常消耗や全欠損（以下、脱落」で統一する）が原因で構造物表面の電位が防食電位より貴化し、防食状態が維持されなくなる部位が発生する可能性がある。一般に、1 個の犠牲陽極が機能しなくなっても周囲の犠牲陽極によりその部位の防食状態は保たれる。しかし、複数の犠牲陽極が局所的に脱落した場合には防食状態が維持されなくなる可能性が考えられる。通常行われる防食状態の検査では、海中に参照電極を投入して構造物近傍の電位を測定し、その部位の防食電位が維持されているかを確認している。しかし、犠牲陽極が多数であり、かつ構造物の形状が複雑な場合、貴化の生じやすい部位や防食状態が維持できなくなる脱落個数の予測が困難である。このため、より効率的な電位測定や防食設計への反映が行なわれていないのが現状である。

本章では有限要素法を用いて海洋構造物における犠牲陽極脱落に対する防食限界の推定法の開発を行う。すなわち、犠牲陽極の脱落を想定した数値解析を行い、防食状態を維持できなくなる条件を推定する。具体的には、複数の犠牲陽極脱落を全ての組み合わせについて計算し、防食限界となる際の犠牲陽極の脱落個数と、危険となる部位を推定する。最後に、データサイエンスを活用した電位計測値から想定される犠牲陽極脱落パターンの推定手法を提案する。

7.2 解析対象

7.2.1 解析対象施設の概要

2010 年 10 月に供用が開始された羽田空港 D 滑走路は、多摩川の河川流の通水性を確保するために埋め立て構造と栈橋構造が組み合わされており、栈橋構造はジャケットと呼ばれる構造物 198 基で構成されている。犠牲陽極はジャケット 1 基あたり約 90 個設置されており、栈橋部全体ではその総数は約 16,000 個である。そのため、効率的かつ経済的な防食状態の検査手法が望まれている。なお、大野らの解析⁶³により、1 つのジャケットの防食状態は、周囲のジャケットの影響を受けないことが確認されている。そのため、本研究では 1 つのジャケットを解析対象とする。

7.2.2 数理モデルの設定

構造物形状情報、海中・土中の電気伝導度、そしてカソードの分極曲線を線形近似したデータを用いて、有限要素法により構造物の表面電位の計算を行う。なお、構造物表面電位とは、実際の構造物のごく近傍における海水の電位を表す。ジャケットのモデルを **Figure 55** に示す。解析領域として、構造物周辺の海水および海底土で満たされた領域 Ω を考える。領域の境界は、犠牲陽極表面のアノードとなる境界 Γ_a 、骨組の鋼材で、カソードとなる境界 Γ_{c1} 、 Γ_{c2} （それぞれ海中、土中の鋼材を表す）、海面付近の耐海水性ステンレス鋼でカソードとなる境界 Γ_{c3} 、海水を仮想的に分割した海中領域の鉛直面境界（以下、海中壁と呼ぶ） Γ_{sea} 、海中領域の上部の境界 Γ_{air} 、そして海底土を仮想的に分割した土中領域の境界 Γ_{soil} で囲まれる。領域内の電位を ϕ 、電気伝導率を κ 、そして境界における法線方向の電流密度を i とする。

領域においてイオンの損失や増加が生じないとし、海中と土中の電気伝導率が不均一である点を考慮すると、領域内の電位 ϕ は支配方程式として式(107)を満足する。また境界上の電流密度は式(108)で表される。 $\partial/\partial n$ は外向き法線方向微分を表す。なお本稿では解析上、電位 ϕ は金属に対する海水の電位を考えているため、通常電気化学で用いる、溶液に対する金属の電位の符号を逆転させている。

$$\nabla \cdot (\kappa \nabla \phi) \quad (107)$$

$$i \equiv \kappa \frac{d\phi}{dn} \quad (108)$$

ここで境界条件をそれぞれ次式で与える。

$$i = f_1(I_{\text{anode}}), \quad \text{on } \Gamma_a \quad (109)$$

$$\phi = -R_S i + \phi_S, \quad \text{on } \Gamma_{c1}, \Gamma_{c2} \quad (110)$$

$$\phi = -R_{\text{sus}} i + \phi_{\text{sus}}, \quad \text{on } \Gamma_{c3} \quad (111)$$

$$i = 0, \quad \text{on } \Gamma_{\text{air}}, \Gamma_{\text{soil}}, \Gamma_{\text{sea}} \quad (112)$$

式(109)において、 $f_1(I_{\text{anode}})$ は Γ_a 上において電流量 I_{anode} が流れる際の一様電流密度である。犠牲陽極は、その表面抵抗と自然電位により電流量が決まるが、本検討では通電初期を想定して、全ての犠牲陽極から同じ量の電流が発生すると仮定した。そのため、電流量を犠牲陽極の表面積で除した電流密度を、犠牲陽極の境界条件として与えた。また式(110)(111)において、鋼材およびステンレス鋼の分極曲線は一般的に非線形であり、本検討における検査対象である防食管理電位付近の電位域では、カソード反応電流は電位に依存する。しかし、防食状態にある構造物表面電位の平均値から、犠牲陽極の局所的な脱落が起きた際の構造物の表面電位の最貴値までの電位差は最大 100mV 程度であるので、その範囲内での分極曲線を線形近似して解析の境界条件を定めた。例として、防食状態を模擬して海水中で 1000mV に約 300 日間保持した後に測定した鋼材試験片の分極曲線を **Figure 56** に示す。ここから、鋼材境界 Γ_{c1}, Γ_{c2} における分極抵抗 R_S 、および線形近似の際の定数項 ϕ_S を求めた。ステンレス鋼境界 Γ_{c3} についても同様に、分極抵抗 R_{sus} および線形近似の際の定数項 ϕ_{sus} を求めた。解析領域の外側境界は式(112)の通り、すべて絶縁境界とした。式(109)(110)(111)(112)の条件のもと、式(107)を数値解析で解くことにより、構造物表面の節点における電位を計算する。




Figure 55 Boundary conditions of a jacket structure in the cathodic protection




Figure 56 The measured polarization curve (steel, kept in the sea water for 300 days at -1000mV)

7.3 犠牲陽極脱落による防食限界の推定

7.3.1 検証内容

犠牲陽極の脱落により、構造物表面電位が最も貴化する部位の推定を行う。90個の犠牲陽極のうちから n 個 ($n=0, 1, 2, \dots$) の犠牲陽極が脱落したと仮定して構造物表面電位を計算する。犠牲陽極の脱落はすべての組み合わせについて検討する。すなわち n を順次増やしながらか ${}_{90}C_n$ 通りの計算を実施し、構造物表面電位が防食管理電位より貴化する点が現れる脱落個数およびパターンを探索する。電位の判定対象は、有限要素モデルの海中部の鋼材の全節点(31,023点)とし、防食管理電位は 0.80V vs. Ag/AgCl[sw] (以下 V と称す) とする。

7.3.2 数値計算モデル

数値計算に使用する有限要素モデルの概形を **Figure 57** に示す。数値は順解析の一例であり、海水部分にメッシュが作成された状態から、手前半分を除去した断面図を示している。また、防食状態の検査対象である海中部分のジャケット構造を **Figure 58** に示す。海中領域のジャケットの大きさは縦 63m、横 45m、高さ 18.2m であり、節点数は 207,047、要素数は 1,054,503 である。上部 1.5m が耐海水性ステンレス鋼、それより下の部分を鋼材とし、アルミニウム合金犠牲陽極は 90 個設置されているとする。境界条件は、海洋構造物の通電初期の理想的な防食状態を想定して、**Table 11** のように設定する。犠牲陽極については、1 個当たり設計発生電流量 3.5A が、一様な電流密度で発生しているとする。鋼材については、分極抵抗は通電開始前の鋼材サンプルの分極曲線を線形近似したものを、定数項は、全犠牲陽極が機能している際の構造物表面電位計算値の最貴値が 0.81V となるように定める。これは、アルミニウム合金犠牲陽極の鋼材に対する有効電位差が 0.25V、アルミニウム合金の自然電位が 1.06V であるので、犠牲陽極から上記の設計電流量が発生するのは構造物の表面電位が 0.81V の時であり¹¹⁶、その際に構造物のすべての部位において、表面電位が 0.81V よりも卑に保たれていると仮定したためである。ステンレス鋼の分極抵抗および定数項については、通電開始前のサンプルの分極曲線を線形近似したものをを用いる。電気伝導度は **Figure 59** に示すように、水面から水深 8m にかけては水深に対して 1 次関数的に増加し、その後海底までは一定値とする。また、土中部分の電気伝導度は 1.0S/m とする¹¹⁶。




Figure 57 FEM model for the Haneda D-runway jacket structure




Figure 58 Geometry of the Haneda D-runway jacket structure

Table 11 Boundary conditions for the FEM analysis

Boundary	Place	Boundary conditions
Γ_a	Sacrificial anode	$I_a = 3.5 \text{ [A]}$
Γ_{c1}	Steel (Sea section)	$\phi_{c1} = -1.0i + 0.7432 \text{ [V]}$
Γ_{c2}	Steel (Soil section)	$\phi_{c2} = -1.0i + 0.7432 \text{ [V]}$
Γ_{c3}	Stainless	$\phi_{c3} = -0.3i + 0.4 \text{ [V]}$
$\Gamma_{sea}, \Gamma_{soil}, \Gamma_{air}$	Imaginary wall	$i = 0 \text{ [A/m}^2\text{]}$




Figure 59 Electric conductivity of the sea water(0~18m) and soil(18m~)

7.3.3 防食限界の推定結果

犠牲陽極の仮想的な脱落個数を 0 個から順番に増やし、危険な脱落パターン(構造物表面電位が防食管理電位より貴化した脱落の組み合わせ)の推定を行った。犠牲陽極の脱落個数、全組み合わせ数、危険パターン数、最貴電位を **Table 12** に示す。まず、適正な防食状態(脱落が 0 個)の時、**Figure 60** に示される四隅レグの下側接続部分内側の電位が最も貴化した。次に、犠牲陽極を 2 個脱落させた時点で、その部位に防食管理電位より貴化した節点が出現した。なお、犠牲陽極脱落個数が 3 個の場合、危険パターンが 1,046 通りになった。脱落個数 2 個の場合を含んだ全てのパターンが危険と判定されたためである。

Table 12 Estimation results of the number of anode lack patterns and the noblest potential

Lack	Combination	Pattern	Noblest voltage
0	1	0	0.8100 [V]
1	90	0	0.8016 [V]
2	4,005	50	0.7945 [V]
3	117,480	1,046	0.7890 [V]




Figure 60 The noblest voltage point without anode lack

7.3.4 脱落個数 2 個の時の危険パターン

ある 1 つの隅における犠牲陽極の配置、および脱落させる犠牲陽極候補を **Figure 61** に示す。犠牲陽極脱落により、構造物表面が防食管理電位より貴化するパターンは 13 通りで、その中でも (B, C) のパターンの際に構造物の表面電位が最も貴化した。**Table 13** に危険パターン 13 通りの犠牲陽極脱落パターンを示す。したがって、通電初期のジャケットで最も危険になりやすいのは四隅レグ下側接続部分

内側であり，危険となる脱落個数は 2 個であった．海底付近の犠牲陽極は，水面付近に比べて多めに設置されているが，地下 70m まで打ち込まれている土中の鋼材の防食を担っているため，その脱落が防食状態に与える影響が大きいためと考えられる．その他の部位については，通電初期の犠牲陽極 2 個の脱落時でも，全てのパターンにおいて防食管理電位が維持されることが確認された．




Figure 61 The candidates of anode lack

Table 13 All dangerous patterns (2 anodes lack)

Lack	Noblest voltage	Pattern
(B, C)	0.7945 [V]	17
(A, C)	0.7962 [V]	12
(A, B)	0.7961 [V]	3
(B, D)	0.7978 [V]	2
(B, E)	0.7981 [V]	1
(B, F)	0.7986 [V]	1
(B, H)	0.7987 [V]	1
(B, G)	0.7990 [V]	1
(C, D)	0.7991 [V]	1
(C, E)	0.7994 [V]	1
(B, J)	0.7996 [V]	1
(B, I)	0.7999 [V]	1
(C, F)	0.7999 [V]	1

7.3.5 脱落個数を増やした場合の構造物表面電位の変化

犠牲陽極の脱落個数が3個の場合の危険パターンのうち、構造物表面電位が貴な順に上位10パターンを **Table 14** に示す。犠牲陽極の脱落は、(A, B, C) のパターンが最も危険であることがわかる。この場合も、四隅下側が防食上危険になりやすく、通電初期においては、この周辺を重点的に、2個の犠牲陽極が脱落すると危険になるという情報の下、検査間隔を設定するのが良いと考えられる。なお、本検討における電位計算では主に設計情報を利用しており、実際の構造物の情報は含まれていない。そのため、構造物中で貴化しやすい部位の特定は可能であるが、構造物表面電位はあくまでも計算例であることに留意されたい。また、通電初期の海洋構造物は防食状態が不安定であり、一時的に無防食状態になることもある。理由は、通電初期の鋼材は石灰質被膜が形成されておらず、表面電位が貴化しやすいことと、犠牲陽極の発生電流量も低減しておらず、脱落による構造物表面電位への影響が大きいためである。

Table 14 Dangerous patterns (3 anodes lack)

Lack	Noblest voltage	Pattern
(A, B, C)	0.7890 [V]	101
(B, C, D)	0.7907 [V]	58
(B, C, E)	0.7910 [V]	66
(B, C, F)	0.7915 [V]	49
(B, C, H)	0.7916 [V]	49
(B, C, G)	0.7919 [V]	48
(A, B, D)	0.7923 [V]	38
(A, C, E)	0.7924 [V]	54
(B, C, J)	0.7925 [V]	41
(A, B, E)	0.7926 [V]	33

7.3.6 通電中期を想定した解析例

本章の解析例では、設計時を想定して通電初期の検証を行ったが、石灰質被膜形成、電流低減後であれば、犠牲陽極脱落個数の条件は緩和されると考えられる。そこで、通電中期を想定した解析例を示す。**Table 11** の境界条件において、鋼材の分極抵抗を $1.0\Omega\text{m}^2$ から $2.0\Omega\text{m}^2$ に増加、犠牲陽極の電流量を 3.5A から 1.5A に低減させて、同様の解析を行った。すると、犠牲陽極3個 (A, B, C) の脱落時に、四隅において防食管理電位付近の電位の節点が数点現れた。さらに犠牲陽極4個の脱落時に防食管理電位より貴化した節点が多数出現し、(A, B, C, E), (A, B, C, D) といったパターンにおいて最大 0.796V まで貴化した。したがって通電中期以降では、犠牲陽極3個程度の脱落が起こると、防食状態が維持されなくなる部位が出現すると考えられる。しかし、通電中期以降の解析は、設計値やサンプルの値を解析に用いれば良い通電初期と異なり、モデルに境界条件を正確に与えることが困難である。本手法の解析結果は、与える境界条件に依存するため、通電中期以降の解析を行うには、運用中の海洋構造物から境界条件データを得ることが必要となる。

7.4 データサイエンス活用による今後の展望(犠牲陽極脱落パターンの逆推定)

本章における検討では、FEM 解析にて各犠牲陽極単品の防食効果を計算し、電場解析の線形性を利用し、各犠牲陽極による防食効果の重ね合わせで全パターンを表現した。その上で、鋼材表面に防食電位を下回る部位が出現する犠牲陽極脱落パターンを、全パターン評価により導出を行った。しかし、実際に犠牲陽極の脱落が発生した際は、電位測定値に基づく異常検出後に、ダイバーや水中カメラなどを用いて犠牲陽極を点検することが想定される。この際、どの順番で点検するかは、本章で提示された脱落パターンを基に人間が判断する必要がある、非効率性が残ってしまう。そこで、犠牲陽極脱落パターンと、その際の構造物周囲の電位の関係を、機械学習を用いて学習することを考える。

Figure 62 に、推定コンセプトを示す。FEM による陽極脱落解析の結果得られる、構造物周囲の電位分布計算値を入力データ、その際の境界条件(犠牲陽極の脱落位置)を教師データとして学習モデルを構築する。そして、構造物周囲の電位を測定した際に、想定される犠牲陽極脱落パターン(位置、個数)を出力させる。すると、電位計測値から想定される脱落シナリオに基づいて詳細検査の計画を立てることができ、検査効率および安全性の向上が可能となる。また本章の検討では、陽極 1 個の脱落では電位分布に有意な変化が見受けられず、検出することが困難であったが、機械学習の適用により微細な特徴を検出できる可能性がある。




Figure 62 Concept of the anode-lack scenario estimation by utilizing machine learning

7.5 まとめ

社会インフラの1つである大型海洋鋼構造物の電気防食設計及び検査の効率化に向けて、犠牲陽極の脱落を想定した数値解析を行い、防食状態を維持できなくなる条件を推定した。具体的な取り組みは以下の通りである。

- (1) 構造物形状情報、海中・土中の電気伝導度、および金属の分極曲線を線形近似したデータを用いて、有限要素法による電場計算を行った。
- (2) 複数の犠牲陽極が脱落した状況における構造物表面電位を計算し、モデル上の鋼材全節点 31,023 点について、防食管理電位 0.8V を満たさなくなる危険節点を探索した。
- (3) 脱落個数を順次増やしながら、全ての犠牲陽極脱落の組み合わせについて上記の比較を行い、構造物表面電位が防食管理電位よりも貴化する際の犠牲陽極脱落個数およびパターンを示した。
- (4) 羽田空港 D 滑走路棧橋部ジャケットを例として、通電初期における防食限界の推定を行った。四隅レグの海底側において、局所的に 2 つの犠牲陽極脱落が起きると防食状態が維持されなくなる部位が出現することを示した。
- (5) 機械学習を用いて、測定された電位分布から、想定される犠牲陽極脱落シナリオを推定することで、検査効率および安全性の更なる向上が期待される。

8.1 本章の目的

内燃機関の脱炭素化を実現するためには、再生可能エネルギーから生成される燃料である **e-Fuel** の利用が一つの選択肢となり得る。**e-Fuel** は、従来型燃料との混合燃料として導入されることが予想され、市場導入された場合は燃料特性の不確実性が増大する。また、**PHEV** を始めとする低燃費ハイブリッド車の普及により給油頻度が減り、燃料が車両タンク内に半年以上の長期に渡り保管されることが想定される。多種燃料が長期に渡り保持される将来エンジンには、タンク内燃料の混合や劣化による特性変化をモニタリングする技術が必要になると考えられる。本章では、外部情報と車載エンジン部品の信号情報をデータ同化を用いて融合する、新しい燃料混合率推定法を検討する。アンサンブルカルマンフィルタを用いて、給油や燃料劣化、およびそれらの不確実性を考慮してタンク内の燃料混合率を予測するフレームワークを構築し、日常的な車両運行スケジュールを想定した数値実験を行い、提案手法の有効性を検証する。

8.2 多種燃料対応エンジンコンセプト

8.2.1 e-Fuel の定義

Figure 63 にドイツ自動車工業会(VDA)の示す **e-Fuel** の定義を示す¹²¹。**e-Fuel** は、風力などの再生可能エネルギー由来の電力と CO_2 を用いて化学的に合成される燃料である。 CO_2 は工場の排気やバイオマス、または大気からの吸収により得ることが想定される。これに対して、セルロース等のバイオ資源より生成されるアルコール燃料はバイオ燃料と分類される。**e-Fuel** とバイオ燃料を合わせて、 CO_2 フリー燃料または再生可能燃料と呼ぶ。バイオ燃料は更に、小麦や菜種油、パーム油等から生成される第一世代バイオ燃料と、廃棄物や残留物、および藻類から生成され、食糧生産と競合せず持続可能な第二世代バイオ燃料に分類される。**e-Fuel** は更に、ガス燃料である **CNG** や水素を用いた **e-Gas** や **e-Hydrogen**、および液体燃料である **e-Diesel**、**e-Gasoline** に分類される。従来バイオ燃料以外の、人工的に精製される燃料を総称して、合成燃料(**Synthetic fuel**)と呼ぶ。**e-Fuel** のうち、**CNG** や水素といったガス燃料車は既に市場導入が始まっているが、給油インフラの普及が進んでいない点や、ガス燃料を搭載するための車両コストが高い点等により、環境対応車の普及が進んでいる EU であっても、新車販売に占める割合は 2019 年時点で 2%以下に留まっている。一方、液体状態で使用される **e-Diesel** および **e-Gasoline** は、従来と同じく液体燃料タンクでの保存が容易であり、既存の内燃機関車に大きな改修を施すことなく用いることができるため、車両コストの増加を抑えることができる。**e-Fuel** を使うことで、既に市場に出ている車の CO_2 排出も低減することができるため、新車置き換えが前提となる電動化を補間する技術として、注目が高まっている。




Figure 63 A definition of e-Fuels

8.2.2 e-Fuel 基本特性

Table 15 にガソリンとバイオ燃料，そして代表的な e-Fuel の物性値を示す．ガソリンは欧州における標準ガソリン燃料である RON95 を示している．バイオ燃料としてはエタノール及びメタノールがあり，両燃料ともガソリンとの混合燃料として既に広く用いられている．エタノール 100%燃料はブラジルで実用化されており，メタノール 100%は中国の一部地域で，利用する人々の健康影響を調べるパイロットプログラムが完了し，実用化に向けた検討が進んでいる¹²²．またメタノールは，バイオマス原料から精製されるものと，水蒸気改質法のような工業的製造方法により生成されるものが存在する¹²³．従来はコストの関係から工業的製造方法の方が主流であり，かつ原料としては化石燃料である天然ガスが用いられていたため，バイオマス由来のメタノールの割合は限定的であった．近年，化石燃料を使わずにメタノールを生成する方法のコスト低減により，再生可能エネルギーから精製されるメタノールが，e-Fuel の 1 つとしても注目されるようになった．バイオ燃料の特徴としては，自着火温度およびオクタン価 (Research Octane Number, RON) がガソリンと比べて高く，ノック耐性が高い．一方，低位発熱量 (Lower Heating Value, LHV) がガソリンと比べて低い点，そして蒸発エンタルピーがガソリンに比べ 2 倍以上高く，揮発しにくい点が挙げられる．そのため，低温始動性の悪化がバイオ燃料対応の主要課題となっている．

e-Fuel は分子中に酸素原子を含む含酸素燃料であり，一酸化炭素(CO)のような有害な中間生成物が酸化されやすい．また分子中に C-C 結合を含まず，粒子状物質(Particle Number, PN)の核となる低級炭化水素(C1~C4)が形成されないことから，PN 排出量が小さい特徴がある．今回，ガソリンエンジン向け e-Fuel の有力候補として考えられている，ジメチルカーボネート(DMC, Dimethyl carbonate)およびギ酸メチル(MeFo, Methyl Formate)，および e-Fuel とバイオ燃料同士の混合燃料である DMC+を e-Fuel の代表例とした．DMC はメタノールと一酸化炭素と酸素から合成され，塗料や接着剤，洗浄剤やリチウ

ムイオン二次電池の電解液にも用いられている。DMC は比較的ガソリンと近い蒸発特性を持つが、融点が 0℃よりも高く、極低温時は凍結してしまう。MeFo はメタノールと一酸化炭素から合成され、速乾剤や殺虫剤としての用途があり、有毒である。MeFo は融点がガソリンよりも低く耐凍結性については問題無いが、沸点が 31.5℃と非常に低く、高温時の蒸発や、噴射時の減圧沸騰による噴霧形状変化などが課題となる。このように沸点や融点、有毒性などは燃料ごとに異なるが、複数種類の e-Fuel を混合することで、従来ガソリン燃料に近い物性を実現できる見込みである。DMC+はこれらの課題を解決するために考案された e-Fuel 同士の混合燃料である。沸点や融点および蒸気圧曲線等の変化を考慮し、DMC, MeFo, 更にエタノールの含有量が最適化されている¹²⁴。DMC+を再生可能エネルギーおよびバイオ燃料から精製することができれば、化石燃料を一切使用しないため、Well-to-Wheel CO₂をゼロにすることが可能となる。e-Fuel の燃焼観点での特徴としては、低位発熱量がバイオ燃料よりもさらに小さく、同じエネルギーを投入するのに質量ベースで約 2.6 倍、体積ベースで約 1.8 倍の燃料が必要である。自着火温度およびオクタン価は 110 前後であり、エタノール同様に高いノック抑制効果を持つ。含酸素量は 50% 超とバイオ燃料よりも高く、酸素原子の含有形態も、バイオ燃料ではヒドロキシ基(-OH)として含有されるのに対し、e-Fuel はケトン基(-C=O)の形で含まれる。これは、バイオ燃料よりも更に燃料酸化が促進され、排気低減が期待できる一方、ケトン基に起因して、ホルムアルデヒドやアセトアルデヒドといった人体に有毒なアルデヒド排気、ガソリンに比べて増加する恐れがある。

Table 15 Fuel properties of gasoline, biofuels, and e-Fuels

No.	(1)	(2)	(3)	(4)	(5)	(6)
Fuel	Gasoline	Ethanol	Methanol	DMC	MeFo	DMC+
Chemical formula	$C_nH_{1.85n}$	C_2H_5OH	CH_3OH	$C_3H_6O_3$	$C_2H_4O_2$	Blend
LHV [MJ/kg]	42	26.78	19.94	15.80	15.80	16.34
Density (15°C) [kg/m ³]	747.5	794	790	1079	957	1024
RON [-]	95	111	>102	≥ 109	115.0	>110
Ignition temperature [°C]	220	400	465	458	450	>400
Oxygen content [wt.%]	<2.7	34.7	49.4	53.3	53.3	52.6
Theoretical A/F [-]	14.3	9.07	6.46	4.64	4.64	4.86
Boiling point [°C]	30~210	78.5	65.0	90.0	31.5	89.4
Melting point [°C]	-45	-114	-97	0.5~4.7	-100	>-32
Vapor pressure [kPa]	45-100 (37.8°C)	15.5 (37.8°C)	12.9 (20°C)	10.8 (37.8°C)	119.80 (37.8°C)	59.2 (37.8°C)
Enthalpy of vaporization [kJ/kg]	420	910.8	1101	418	464	459.36
Dyn. Viscosity[mPas]	<0.5 (40°C)	1.54 (20°C)	0.544 (25°C)	0.63 (20°C)	0.36 (20°C)	0.473 (20°C)

8.2.3 多種燃料エンジンの課題

混合燃料の燃焼特性は、各燃料それぞれの特性や、混合比率によって変化するため、エンジン制御パラメータは、燃料の混合比に応じて最適化する必要がある。e-Fuel の社会実装を想定すると、既存燃料へ混合する(ドロップイン)形態で使用されることが予期される。また、給油所に供給される燃料の e-Fuel 混合割合も、当該エリアの再生可能エネルギー状況によって変動する可能性もある。Figure 64 に、多種燃料の導入時に想定される燃料特性の不確定性を示す。各燃料は規格化された特性を有していても、それらが混合された状態で供給された場合、自動車の燃料タンク内では燃料特性に大きな不確定性が生じる。例えば、タンク内におけるバイオ燃料や e-Fuel の割合が増えると、LHV は低下する。何度か給油と走行を繰り返すと、燃料タンク内の混合燃料は初期とは異なる LHV を持つようになる。LHV だけでなく、RON、気化エンタルピー等も逐次、変化していく。ここに燃料の劣化が加わると、不確定性はさらに増大する。

混合燃料に対するエンジン制御を最適化するためには、燃料の混合比率と経年劣化の状態を推定する必要がある。しかし、既存の FFV 技術では、ガソリンとエタノールの混合を想定した 2 種類の燃料にしか対応できず、e-Fuel が加わった場合の 3 種類以上の燃料の混合比率を推定することが困難である。また、燃料の特性を検出するための専用センサーを新たに導入することは、システムコスト増大の観点で難しい。

本検討では、外界情報とオンボードの情報をデータ同化により組み合わせ、タンク内の燃料性状を推定する枠組みを検討する。燃料タンク内の燃料性状推定は、前章で検討したような、既に搭載されたコンポーネント信号を活用することが直接的アプローチであるが、それを補完する形で給油所から供給される燃料についての外部情報を組み合わせることで、より高精度に燃料性状を推定できる可能性がある。本論文では、将来の多燃料化を想定した高精度な燃料混合比推定を実現するために、データ同化のアプローチを適用する。




Figure 64 Image of the fuel property uncertainty in case of the multi-fuel implementation

8.3 データ同化を用いた燃料混合率推定モデルの構築

8.3.1 データ同化の定式化

データ同化とは、モデルの予測結果と観測データの不確定性を考慮して、最も確率の高い推定値を求め

る手法である。Figure 65 に本研究で行ったアンサンブルカルマンフィルタ（EnKF）に基づくデータ同化の計算フローを示す。EnKF は入力パラメータの確率分布を表現するためにアンサンブルデータを生成し、各アンサンブルについて計算を行った結果から出力パラメータの確率分布を生成する手法である。非ガウス分布の確率的パラメータや、非線形システムモデルにも適用が可能である。

データ同化のフレームワークは、システムモデルと観測モデルから構成される。システムモデルは先験的な情報と物理モデルに基づいて将来のデータを予測し、観測モデルは測定データと推定されたパラメータとの関係を記述する。まず、式(113)に示されるシステムモデルにより将来データの予測が実行される。

$$\mathbf{x}_{(t|t-1)} = f(\mathbf{x}_{(t-1|t-1)}, \mathbf{v}_t) \quad (113)$$

ここで $\mathbf{x}$ は、燃料混合率などの推定量である。 $\mathbf{x}_{(t|t-1)}$ の左の添え字は推定が実行された時刻、右の添え字は測定データ入手可能な時刻を示し、この場合は、時刻 $t-1$ の情報に基づく、時刻 t での推定値である。 $f_t()$ はシステムモデルで、推定値の時間更新を記述する物理モデルである。 $\mathbf{v}_t$ はシステムノイズであり、時間更新時に想定される誤差を付与する。本研究では、燃料経年変化モデルの誤差と、給油された混合燃料の不確定性を想定している。次に測定データ $\mathbf{y}_t$ を取得して、式(114)に示す観測モデルを用いて、予測した $\mathbf{x}_{(t|t-1)}$ との関係を記述する。

$$\mathbf{y}_t = h_t(\mathbf{x}_{(t|t-1)}, \mathbf{w}_t) \quad (114)$$

$h_t()$ は観測モデルである。 $\mathbf{w}_t$ は観測ノイズであり、一般的には想定される測定誤差を与える。最後に、予測値 $\mathbf{x}_{(t|t-1)}$ と測定値 $\mathbf{y}_t$ は、以下の式で同化される。ここで、 i, j はアンサンブルメンバーの数である。まず式(115)を用いて、アンサンブルメンバー $\mathbf{x}_{t|t-1}^{(i)}$ の擾乱ベクトル $\tilde{\mathbf{x}}_{t|t}^{(i)}$ を計算する。そして、式(116)へ代入することで、推定量の分散共分散行列 $\hat{\mathbf{V}}_{t|t-1}$ を得る。

$$\tilde{\mathbf{x}}_{t|t}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{x}_{t|t-1}^{(j)} \quad (115)$$

$$\hat{\mathbf{V}}_{t|t-1} = \frac{1}{N-1} \sum_{j=1}^N \tilde{\mathbf{x}}_{t|t-1}^{(i)} \tilde{\mathbf{x}}_{t|t-1}^{(i)'} \quad (116)$$

次に、乱数を用いて式(117)を計算し、観測ノイズのアンサンブル $\{\mathbf{w}_t^{(i)}\}_{i=1}^N$ を生成する。そして、各アンサンブルに対して式、測定誤差のサンプル分散共分散行列 $\hat{\mathbf{R}}_t$ を式(118)を用いて計算する

$$\tilde{\mathbf{w}}_t^{(i)} = \mathbf{w}_t^{(i)} - \frac{1}{N} \sum_{j=1}^N \mathbf{w}_t^{(j)} \quad (117)$$

$$\hat{R}_t = \frac{1}{N-1} \sum_{j=1}^N \tilde{w}_t^{(j)} \tilde{w}_{t|t}^{(j)'} \quad (118)$$

式(119)によりカルマンゲイン $\hat{K}_t$ を計算し、式(120)により最終的な推定結果 $\mathbf{x}_{t|t}^{(i)}$ を得る。

$$\hat{K}_t = \hat{V}_{t|t-1} H_t' (H_t \hat{V}_{t|t-1} H_t' + \hat{R}_t)^{-1} \quad (119)$$

$$\mathbf{x}_{t|t}^{(i)} = \mathbf{x}_{t|t-1}^{(i)} + \hat{K}_t (\mathbf{y}_t + \tilde{w}_t^{(i)} - H_t \mathbf{x}_{t|t-1}^{(i)}) \quad (120)$$




Figure 65 Data assimilation calculation flow

ここで、本検討にて想定する入力情報について述べる。燃料タンク内の燃料性状を推定するためには、外部データ、特に給油所からの情報が重要である。近年の自動車は社外通信手段を標準的に備えていることから、給油時には供給した燃料の成分や含有率について、平均値や標準偏差といった不確定性指標が得られると想定した。車両側では、一般的に専用の燃料センサーは搭載されておらず、ノックセンサー、空燃比センサー、インジェクタ、点火コイルなど既存のエンジン部品の信号活用が求められる。既存のエンジン部品の信号から燃料含有量を推定する技術も広く研究されているが、単体での推定精度は多種燃料の検知には十分ではない。今回は、車載燃料性状センサーについては検討せず、観測値として正しい燃料混合率にランダム誤差を付与した値を直接、取得できると仮定した。

7.3.2 燃料混合率推定モデルの構築

データ同化を活用することで、各測定データの単体精度が不十分であっても、統合されたデータは、実用的な精度の燃料含有率推定を実現する可能性がある。外部情報（ガソリンスタンドなど）と車載データ（エンジン部品）を活用し、データ同化手法を燃料含有率推定に適用した。以下、システムモデルと観測モデル構築の詳細を説明する。

[1] 燃料混合率と車両オペレーションの設定

燃料混合率 $\mathbf{x}$ を推定量として、式(121)を定義する。本検討では 4 種類の燃料と、劣化ガソリンの合計 5 種類を想定した。 $x_{Gasoline}$, x_{DMC} , $x_{Ethanol}$, $x_{Methanol}$, $x_{Old gasoline}$ は各燃料の混合割合である。

$$\mathbf{x}_t = [x_{Gasoline}, x_{DMC}, x_{Ethanol}, x_{Methanol}, x_{Old gasoline}] \quad (121)$$

次に車両が運用されるパターンを定義する。**Figure 66** は、車両の典型的な運転パターンであり、駐車、走行、燃料センシング、給油の 4 種類で構成されている。駐車とは、車両が自宅やオフィスに駐車し、走行していない状態である。タンク内の燃料量は変化しないが、経年変化により燃料特性が変化する。本検討では、経過時間に依存する単純な燃料劣化モデルを導入した。運転では、車両は一定の距離を走行し、燃料を消費する。運転時間は経年変化の時間スケールよりはるかに短いため、運転中の燃料特性の変化は無視することとした。燃料センシングは、走行中に得られるエンジン部品の信号に基づいて燃料混合比を推定するステップである。給油は、燃料量がある閾値よりも少なくなった際に、車両ユーザーが給油所で行うものとした。このような操作を繰り返す車両のユースケースを想定し、タンク内燃料特性をモニタリングシステムを構築した。本検討では、通常の日データ同化で用いられるシステムモデルと観測モデルに対して、今回の車両運用パターンに適合させるために、修正を行った。

Cyber physical system for vehicle operation




Figure 66 Modelled vehicle operations

[2] システムモデル

システムモデルは、過去に蓄積された情報を基に、走行開始時の燃料混合割合の予測を行う。システムモデルの一般式(113)(114)を、駐車状態での燃料経年変化と給油所での燃料量更新を考慮可能となるように式(122)(123)に示すように拡張した。

$$\mathbf{x}_{(t|t-1)} = f_{aging}(\mathbf{x}_{(t-1|t-1)}) + \mathbf{v}_t + \mathbf{M}_t + \mathbf{E}_t \quad (122)$$

ここで $\mathbf{x}_{(t|t-1)}$ は、予測される燃料混合率、 $f_{aging}()$ は燃料劣化関数である、 $\mathbf{x}_{(t-1|t-1)}$ は前の時刻における推定値である。 $\mathbf{v}_t$ はシステムノイズ、 $\mathbf{M}_t$ は給油量、 $\mathbf{E}_t$ は、タンクからの蒸発量を表す。 $f_{aging}()$ は毎日計算され、 $\mathbf{M}_t$ は給油イベントが発生したときのみ追加で計算される。

燃料劣化モデルでは、新品燃料と劣化燃料、2つの燃料特性テーブルを定義する。燃料の状態は、2つの燃料の加重平均を計算する式(123)で求められる。 α_t は劣化燃料の割合を示す劣化係数である。この式により、燃料が劣化した際には劣化燃料の割合が増加し、燃料の性質が劣化燃料に近づいていく。

$$f_{aging}(\mathbf{x}_{(t|t)}) = (1 - \alpha_t)\mathbf{x}_{new} + \alpha_t\mathbf{x}_{old} \quad (123)$$

本検討では、ガソリンと DMC の燃料劣化をモデル化した。ガソリンの場合、時間の経過とともに軽質成分が蒸発し、重質成分の比率が増加する。その結果、蒸気圧が低下し燃料の蒸発性が悪化し、燃料噴射時の混合気均質性悪化、冷機始動時の排気増加等を招く。DMC は、タンク内の水と加水分解することでメタノールに変化してしまうことが知られている。給油モデルは、各給油所が燃料成分情報を確率関数で提供できることを想定した。給油所で供給される燃料の単体成分は、EN228 などの燃料規格で管理される。ここでは、燃料の成分誤差やタンク内の燃料の経年劣化を考慮し、燃料情報は3シグマで5%の誤差があると仮定した。

[3] 観測モデル

観測モデルは、車載コンポーネント信号を用いて予測値を補正することを想定する。燃料性状は定常的である一方、エンジン応答は過渡的であり、運転条件によってコンポーネント信号は変化する。本検討では観測モデルを定常部分と過渡部分に分離し、燃料混合モデル h_t^{Fuel} とエンジン応答モデル h_t^{Engine} の二段階構成とした。燃料混合モデル h_t^{Fuel} は車両の運転条件に依存せず、燃料の混合率と、混合燃料の燃料特性との関係を記述する。エンジン応答モデル h_t^{Engine} は、燃料特性と運転条件によって決まる車載コンポーネント信号の応答を計算する。式それぞれのモデルを式(124)(125)に示す。 $\mathbf{z}_t$ は混合状態の燃料が示す、LHV 等の燃料特性を示す。 $\mathbf{w}$ は想定される測定誤差である。

$$\mathbf{y}_t = h_t^{\text{Engine}}(\mathbf{z}_t) + \mathbf{w}_t^{\text{Engine}} \quad (124)$$

$$\mathbf{z}_t = h_t^{\text{Fuel}}(\mathbf{x}_t) + \mathbf{w}_t^{\text{Fuel}} \quad (125)$$

[4] 燃料混合比推定の計算フロー

Figure 67 は、燃料混合率推定の計算フローである。丸印のアイコンは、アンサンブルを生成し、複数回の計算を実行する、**EnKF** ループが行われることを示している。各ステップにおいて、アンサンブルメンバーの数は 500 とした。パラメータの初期化後、システムモデル計算が実行され、次タイムステップの状態予測が行われる。そして、システムモデルに基づく、走行に起因する燃料消費量の計算と、観測モデルに基づく予測データ補正を行う。また運転終了後、燃料量が特定量より少なくなった場合、給油イベントを挿入し、燃料量を増加させる。最新の混合燃料の推定結果から、オクタン価、蒸気圧等の燃料特性を求めることができ、これらの特性に基づいて、点火時期、燃料噴射次期、または噴射回数などのエンジン制御パラメータを補正することが可能である。最後に、次の時間ループで燃料量と燃料混合率の推定値が更新される。このループを運転日毎に繰り返すことで、燃料タンク内の燃料混合比を長期的に監視することが可能になると考えられる。




Figure 67 Calculation flow of the fuel blend estimation

8.4 数値実験

8.4.1 モデル設定

データ同化を用いた燃料混合率推定の高精度化を確認するための数値実験を行った。Table 16 に、燃料と車両オペレーションに関するパラメータ設定を示す。推定量は、新品ガソリン、DMC、エタノール、メタノール、劣化ガソリン、計 5 種類の混合比率である。燃料タンク容量は 50L で、初期状態はガソリン 95%・エタノール 5%の混合燃料とした。1 日 2 回、30km ずつ走行し、燃料が 5L になった時点で給油を行う。燃料は DMC70%-メタノール 30%の混合燃料である。経年劣化計算のためのシステムモデル更新は 1 時間ごとに実施した。データ同化の有無について計算精度の違いを確認する。

Table 16 Numerical experiment parameters

Parameters	Values
Fuels	Gasoline, Ethanol, Methanol, DMC
Fuel tank volume	50 L
Initial blend ratio	Gasoline(new) 95% - Ethanol 5%
Refueled blend ratio	DMC 70% - Methanol 30%
Refuel threshold	5 L
Average fuel economy	20 km/L (Gasoline equivalent)
Calculated period	30 days
Driving frequency	2 times/day
Distance per one driving	30km
Prediction interval	1 hour

8.4.2 計算結果

Figure 68 は、データ同化を実施せず、予測計算のみを行った場合の燃料混合率推定結果である。上段のグラフは、燃料タンクの燃料量と累積走行距離である。燃料量は日々の走行により減少し、燃料量が 5L 以下になると給油が行われている。下段のグラフは、各燃料の混合率を示しており、それぞれ黒線が真値である。日数の経過とともに、燃料の経年変化により、新品ガソリン(赤)の割合が低下し、代わりに劣化ガソリン(ピンク)が増加している。同じ色の複数の線は、各アンサンブルの計算結果を示しており、全てのアンサンブル結果を描画することで、推定誤差の範囲を表現している。各燃料成分の含有率推定結果の誤差は、時間の経過とともに増加し、システムノイズ相当の変動幅に収束する。誤差は給油直前が最大となり、給油により含有率既知の燃料が投入され、タンク内燃料の大半を占めるようになると、誤差は大幅に低減する。そして再び、次の給油までの期間は、日々の予測計算により誤差振幅が増大していく。このように、データ同化を行わない場合は、給油時以外は燃料情報を取得する機会がなく、推定結果はシステムモデルの予測精度に依存した誤差範囲を持つことになる。

Figure 69 は、データ同化を実施した場合の燃料混合率推定結果である。1 日 2 回、車両走行の際に車載センサーによる燃料含有率推定を行い、データ同化により燃料混合率の予測結果を補正した。システムモデルにより 1 時間毎に実施される予測計算により誤差振幅は拡大するが、走行後のデータ同化によ

り直ちに振幅が下方修正される。その結果、データ同化無しに比べて誤差振幅が給油直前でも増大することなく、継続的に正解値に追従できることが確認できた。

本検討は数値実験による、データ同化フレーム枠の理論検証の位置づけとなる。実用化に向けた次のステップとして、車載センサーから燃料混合率を推定する技術の開発が必要となる。車載センサーとしては、エンジンブロックの振動を計測するノックセンサー、クランクシャフトの回転速度変化を検出するクランク角センサー、シリンダーに燃料を供給するインジェクタ、火花を発生させて混合気を点火する点火コイルなどが候補に挙がる。それぞれの部品を用いたセンシング技術に関する検討は、第2章で述べた通り、既に数多く行われている。しかし、単体での検出範囲や精度が不足することから、燃料混合率推定への活用は進んでいない。データ同化アプローチは、複数のセンサーからのデータを、それぞれの情報の信頼性を考慮して統合することができる。これにより、混合燃料の正確な推定が可能となり、混合燃料に応じた最適なエンジン制御が可能となると考えられる。




Figure 68 Fuel blend estimation result (without data assimilation)




Figure 69 Fuel blend estimation result (with data assimilation)

8.5 まとめ

内燃機関の脱炭素化を実現するための手段の1つである e-Fuel の活用に向けて、タンク内燃料の混合や劣化による特性変化をモニタリングする技術が求められる。本章では、外部情報と車載エンジン部品の信号情報をデータ同化を用いて融合する、新しい燃料混合率推定法を検討した。具体的な取り組みは以下の通りである。

- (1) アンサンブルカルマンフィルタを用いて、給油や燃料劣化、およびそれらの不確定性を考慮してタンク内の燃料混合率を予測するフレームワークを構築した。
- (2) 駐車中の燃料劣化による成分変化と、給油時のタンク内混合率変化を予測するシステムモデルと、車載センサー情報に基づき燃料混合率の予測結果を補正する観測モデルで構成されるデータ同化モデルを構築した。
- (3) 日常的な車両運行スケジュールを想定した数値実験を行い、データ同化により燃料混合率の変化を継続的に推定できることを確認した。
- (4) 実用化に向けた次のステップとして、車載センサーから燃料混合率を推定する技術の開発が必要となる。

研究業績

【学術雑誌発表論文(査読有)】

- [1] 米谷 直樹, 天谷賢治, 審良 善和, 田代 賢吉, 飯田 知宏, 山路 徹.
ベイズ推定を用いた海洋鋼構造物の犠牲陽極発生電流量同定法の開発,
材料と環境 : zairyo-to-kankyo, Vol. 62, No. 9, pp. 326-333, Sept. 2013
- [2] 米谷 直樹, 審良 善和, 田代 賢吉, 飯田 知宏, 山路 徹, 天谷賢治.
データ同化を用いた海洋構造物の犠牲陽極電流量予測システムの開発,
材料と環境 : Zairyo-to-Kankyo, Japan Society of Corrosion Engineering, Vol. 63, No. 2, pp. 43-49, 2014.
- [3] Naoki Yoneya, Kenji Amaya, Kengo Kumano, Yoshihiro Sukegawa, Yoshifumi Uchise, Hideo Jitsu, Yukio Fujiyama 「Misfire Detection Technology with Deep Neural Network Based on Ignition Coil Signals」
SAE International Journal of Engines17(1):2024, doi:10.4271/03-17-01-0004.

【学術雑誌技術資料(査読有)】

- [4] 米谷 直樹, 天谷賢治, 審良 善和.
有限要素法を用いた海洋構造物における犠牲陽極消耗に対する防食限界の推定
材料と環境 : Corrosion engineering of Japan 62 (1), 11-15, 2013-01

【国際会議における発表(査読有)】

- [5] Naoki Yoneya, Kenji Amaya
「An estimation method of blended fuel contents by data assimilation for carbon neutral powertrain」
SETC(Small powertrains and Energy systems Technology Conference) 2022
JSAE 20229031 / SAE 2022-32-0031

【国内会議における発表(査読無)】

- [6] 米谷直樹, 天谷賢治, 審良善和, 田代賢吉, 飯田知宏.
有限要素法を用いた海洋構造物における犠牲陽極消耗に対する防食限界の推定,
材料と環境, Apr. 2012.
- [7] 米谷 直樹, 天谷賢治, 審良 善和, 田代 賢吉, 飯田 知宏, 山路徹.
ベイズ推定を用いた海洋鋼構造物の電気防食モニタリング法の開発,
第59回材料と環境討論会, 第59回材料と環境討論会予稿集, 腐食防食学会, pp. 257-260, Sept. 2012.
- [8] 米谷直樹, 天谷賢治. データ同化を用いた電気防食予測システムの開発,
第62回理論応用力学講演会, Mar. 2013.

参考文献

-
- ¹¹ Rockström, J., W. Steffen, K. Noone, Å. Persson, et al., "Planetary boundaries:exploring the safe operating space for humanity, " *Ecology and Society* 14(2): 32. (2009)
- ² <https://gaw.kishou.go.jp/> (Referred on June 1st, 2023)
- ³ <https://www.mofa.go.jp/mofaj/gaiko/oda/sdgs/about/index.html> (Referred on June 1st, 2023)
- ⁴ 白井隆裕, 渡辺健太, 井川友裕, "インフラ建設分野の低炭素化に向けた我が国の現状と今後の展望", *JICE レポート* 第 41 号, P22-27, (2022)
- ⁵ https://www.mlit.go.jp/sogoseisaku/maintenance/_pdf/tyouzyumyou2honbun.pdf (Referred on June 1st, 2023)
- ⁶ <https://www.jama.or.jp/statistics/facts/world/index.html> (Referred on June 1st, 2023)
- ⁷ <https://www.env.go.jp/content/900445398.pdf> (Referred on June 1st, 2023)
- ⁸ 富田昇, 今野貢, 服部圭二他, "環境に配慮した我が国初の埋立・栈橋ハイブリッド構造羽田空港D滑走路建設プロジェクト," *三菱重工技報* Vol.48 No.1. (2011)
- ⁹ <https://thesis.ceri.go.jp/db/files/16639846425976b4b837447.pdf> (Referred on June 1st, 2023)
- ¹⁰ <https://data.consilium.europa.eu/doc/document/PE-66-2022-INIT/en/pdf> (Referred on June 1st, 2023)
- ¹¹ <https://ww2.arb.ca.gov/news/california-moves-accelerate-100-new-zero-emission-vehicle-sales-2035> (Referred on June 1st, 2023)
- ¹² http://www.gov.cn/xinwen/2020-11/02/content_5556762.htm (Referred on June 1st, 2023)
- ¹³ https://jcpage.jp/jcevent/file/event/upload/file/301/02_automobile_02_meti_oima_PPT_J.pdf (Referred on June 1st, 2023)
- ¹⁴ https://ec.europa.eu/commission/presscorner/detail/en/ip_22_6495 (Referred on June 1st, 2023)
- ¹⁵ Kramer, U., Bothe, D., Gatzen, C., Reger, M., et al., "The Transformation of Mobility to the GHG-neutral Post-fossil Age," *FVV Fuels Study IV*. https://www.fvv-net.de/fileadmin/Stories/020.50_Sechs_Thesen_zur_Klimaneutralitaet_des_europaeischen_Verkehrssektors/FVV_Future_Fuels_StudyIV_The_Transformation_of_Mobility_H1269_2021-10_EN.pdf (2021)(Referred on June 1st, 2023)
- ¹⁶ 淡路敏之, 蒲地政文, 池田元美, 石川洋一, "データ同化観測・実験とモデルを融合するイノベーション", ISBN978-4-87698-797-9, 学術出版会. (2009)
- ¹⁷ 三好建正, 本田有機, "気象学におけるデータ同化," *日本気象協会 天気*, 54, 4, p.15-18. (2007)
- ¹⁸ 審良善和, 山路徹, 岩波光保, 小林浩之, "港湾鋼構造物の電位計測による電気防食管理方法に関する一提案," *材料と環境* 2012, D-111, P313-316. (2012)
- ¹⁹ Pashley, N., Stone, R., Roberts, G., "Ignition system measurement techniques and correlations for breakdown and arc voltages and currents, " *SAE Technical Paper* 2000-01-0245. (2000)
doi:10.4271/2000-01-0245
- ²⁰ Kim, J., Anderson, R., "Spark Anemometry of Bulk Gas Velocity at the Plug Gap of a Firing Engine, " *SAE Technical Paper* 952459, (1995) doi:10.4271/952459
- ²¹ 国土交通省, "車載式故障診断装置を活用した自動車検査手法のあり方について (最終報告書)," 車載式故障診断装置を活用した自動車検査手法のあり方検討会,
https://www.mlit.go.jp/jidosha/OBD_Inspection_System.html. (2019) (Referred on June 1st, 2023)
- ²² <https://www.vitesco-technologies.com/en-us/products/fluid-sensor-flex-fuel-ethanol> (Referred on June 1st, 2023)
- ²³ Jonathan, T., "How Gauss Determined The Orbit of Ceres," *FIDELIO, Journal of Poetry, Science, and Statecraft*, Vol, VII, No.2. (1998)
- ²⁴ Christoph, S., "Kolmogorov-Wiener Filters for Finite Time-Series,"

<https://ssrn.com/abstract=769584>. (2004)(Referred on June 1st, 2023)

- ²⁵ Kalman, E., R., “A New Approach to Linear Filtering and Prediction Problems,” *Journal of Basic Engineering*, 1960 March, p.35-45. (1960)
- ²⁶ Kalman, E. R., Bucy, S. R., “New results in Linear Filtering and Prediction Theory,” *Journal of Engineering*, 1961 March, p.95-108. (1961)
- ²⁷ McGee, A., L., Schmid, F., S., “Discovery of the Kalman Filter as a Practical Tool for Aerospace and Industry,” *NASA Technical Memorandum* 86847. (1985)
- ²⁸ Ghil, M., “Data Assimilation in Meteorology and Oceanography,” *Advances in Geophysics*, Volume 33, p.141-266. (1991)
- ²⁹ 蒲地政文, “変分法による随伴方程式を用いたデータ同化作用について,” *ながれ* 13, p.440-451. (1994)
- ³⁰ Anderson, D., L., T., Sheinbaum, J., Haines, K., “Data assimilation in ocean models,” *Rep. Prog. Phys.* 59 1209. (1996)
- ³¹ Kamachi, M., Kuragano, T., Ichikawa, H., Nakamura, H., et al., “Operational Data Assimilation System for the Kuroshio South of Japan : Reanalysis and Validation,” *Journal of Oceanography*, Vol.60, p.303-312. (2004)
- ³² 川崎浩司, 戸田圭亮, 藤原建紀, 吉岡典哉, “海洋データ同化システム情報を活用した伊勢湾における貧酸素水塊の長期再現計算,” *沿岸海洋研究* 第 48 巻, 第 1 号, 57-64. (2010)
- ³³ 田中創, 守屋岳, 岩淵哲也, 日下博幸, “WRF-3DVAR を用いたリアルタイム GPS 可降水量の同化実験,” *日本気象学会 天気*, 57.4. (2010)
- ³⁴ 珠玖隆行, 村上章, 藤澤和謙, 西村伸一, “地盤解析におけるデータ同化,” *地盤工学会誌*, 59-3(638), p.8-11. (2011)
- ³⁵ 樋口知之, 上野玄太, 中野慎也, 中村和幸, 他, “データ同化入門-次世代のシミュレーション技術-”, ISBN978-4-254-12786-7, 朝倉書店. (2011)
- ³⁶ 総務省, “AI に関する基本的な仕組み,” 令和元年版 総務省 情報通信白書.
<https://www.soumu.go.jp/johotsusintokei/whitepaper/r01.html> (2019)(Referred on June 1st, 2023)
- ³⁷ McCarthy, J., “The Logic and Philosophy of Artificial Intelligence,” 第 4 回京都賞記念講演録.
https://www.kyotoprize.org/wp-content/uploads/2019/07/1988_A.pdf (1988)(Referred on June 1st, 2023)
- ³⁸ McCarthy, J., “Programs with common sense,” *Proceedings of the Teddington Conference on the Mechanization of Thought Processes*, London. (1959)
- ³⁹ Weisenbaum, J., “ELIZA—a computer program for the study of natural language communication between man and machine,” *Communications of the ACM*, Volume 9, Issue 1, p.36-45. (1966)
- ⁴⁰ Krizhevsky, A., Sutskever, I., & Hinton, G. E., “Imagenet classification with deep convolutional neural networks,” In *Advances in neural information processing systems* (p. 1097-1105). (2012)
- ⁴¹ Silver, D., Huang, A., Maddison, C. et al., “Mastering the game of Go with deep neural networks and tree search,” *Nature* 529, 484–489 (2016). <https://doi.org/10.1038/nature16961>. (2016)
- ⁴² Amari, S., “A theory of adaptive pattern classifiers,” *IEEE Transactions on Electronic Computers* 3 : 299-307. (1967)
- ⁴³ Ruder, S., “An overview of gradient descent optimization algorithms.” *arXiv preprint arXiv:1609.04747*. (2017)
- ⁴⁴ 森守正, “データ同化手法と深層学習を併用したトンネル施工時の湧水量予測に関する基礎的研究,” 岡山大学大学院 環境生命科学研究科 博士論文 甲第 6501 号. (2021)
- ⁴⁵ 宮坂松甫, “「腐食防食講座-海水ポンプの腐食と対策技術-」 第 4 報 : 腐食防食解析技術,” *エバラ時報*, No.223(2009-4), p.37-45. (2009)
- ⁴⁶ 宮田義一, 若林徹, 濱田秀則, “耐海水性ステンレス鋼ライニングを施した海洋鋼構造物の電気防食特性,” *港湾空港技術研究所報告* 第 45 巻第 2 号 June 2006, p.169-196. (2006)

-
- ⁴⁷ 山路徹, 原将之, 能登谷健一, 山廻邊伸充, 他, “海洋鋼構造物に適用された電気防食の維持管理に関する検討,” 港湾空港技術研究所 資料 No.1392. (2021)
- ⁴⁸ Waber, T., J., Fagan, B., “Mathematical Studies on Galvanic Corrosion,” Journal of The Electrochemical Society, Vol.103, No.1, p.64. (1956)
- ⁴⁹ Helle, E., P., H., Beek, M., H., C., and Lygiteijn, TH., J., “Numerical Determination of Potential Distributions and Current Densities in Multi-Electrode Systems,” Corrosion-NACE, Vol.37, No.9, p.522. (1981)
- ⁵⁰ Nagai, K., Iwata, M., “Numerical Analysis of Potential Distribution in Electrolyte under Cathodic Protection : Part 1 Application of Two-dimensional Finite Element Method,” The Japan Society of Naval Architects and Engineers, No.158, p670-678. (1985)
- ⁵¹ Nagai, K., Itawa, M., and Ogawa, K., “Numerical Analysis of Potential Distribution in Electrolyte under Cathodic Protection : Part 2 Application of Three-dimensional Finite Element Method,” The Japan Society of Naval Architects and Engineers, Volume 73, Pages 114-121. https://doi.org/10.14856/wjsna.73.0_114 (1987)
- ⁵² Iwata, M., Nagai, K., “Numerical Analysis of Potential Distribution in Structures under Cathodic Protection -Application of Two-dimentional Boundary Element Method-,” The Japan Society of Naval Architects and Engineers, 1988, Volume 210, p.97-102. (1988)
- ⁵³ Cicognani, P., Gasparoni, F., Mazza, B., and Pastore, T., "Application of the Boundary-Element Method to Offshore Cathodic Protection Modeling," J. Electrochem. Soc., Vol.137, No.6, p.1689-1695. (1990)
- ⁵⁴ Yan, F., J., Pakalapati, R., N., S., Nguyen, V., T., White, E., R., et al., "Mathematical Modeling of Cathodic Protection Using the Boundary Element Method with a Nonlinear Polarization Curve," J. Electrochem. Soc., 139 Vol.7, 1932. (1992)
- ⁵⁵ Fratesi, R., Corradetti, C., Salvi, D., "Laboratory and Computational Study on the Evolution of the Polarization Behaviour of steel Offshore Structures Considering Calcareous Deposit," Marine Structures, p.297-311. (1992)
- ⁵⁶ 田代賢吉, 須藤光, “有限要素法による防食電位電流分布解析,” さび第 135 号. (2002)
- ⁵⁷ DeGiorgi, G., V., Wimmer, A., S., "Geometric details and modeling accuracy requirements for shipboard impressed current cathodic protection system modeling," Engineering Analysis with Boundary Elements, 29, p.15-28. (2005)
- ⁵⁸ Montoya, R., Aperador, W., and Bastidas, M., D., "Influence of conductivity on cathodic protection of reinforced alkali-activated slag mortar using the finite element method," Corrosion Science, 51, p.2857-2862. (2009)
- ⁵⁹ Guibert, A., Chadebec, O., Coulomb, -L., J., and Rannou, C., "Ships Hull Corrosion Diagnosis From Close Measurements of Electric Potential in the Water," IEEE Transactions on Magnetics, Vol.45 No.3, p.1828-1831. (2009)
- ⁶⁰ Ridha, M., Safuadi, Huzni, S., Israr, et al., "The Evaluation of Cathodic Protection System Design by Using Boundary Element Method," Advanced Materials Research, Vol.339, p.642-647. (2011)
- ⁶¹ Lan, Z., Wang, X., Hou, B., Wang, Z., et al., "Simulationofsacrificialanodeprotectionforsteelplatformusingboundary element method," Engineering Analysis with Boundary Elements, 36 [5] p.903-906. (2012)
- ⁶² 滝本 修二, 天谷 賢治, 大西 有希, “犠牲陽極の残存量同定手法の境界要素法解析による検証,” 日本機械学会第 22 回計算力学講演会予稿集, p,109-110. (2009)
- ⁶³ Ohno, H., Amaya, K., "Inverse Analysis of Sacrifice Electrode Current for Large-Scale Marine Structures," Computational Mechanics Division Conference, 602. (2010)
- ⁶⁴ Kramer, U., Goericke, D., and Thee, R., “Energy Paths for Road Transport in the Future,” MTZ

worldwide 80, 18-25. (2019) doi:10.1007/s38313-019-0021-4

- ⁶⁵ Luszcz, P., Takeuchi, K., Gerhardt, M., Adomeit, P. et al., "Homogeneous Lean Burn Engine Combustion System Development—Concept Study," in 18. Internationales Stuttgarter Symposium, Proceedings, Stuttgart, Germany, p.205-223. (2018) doi:10.1007/978-3-658-21194-3_19
- ⁶⁶ Zhang, H., Li, S., Wang, Z., Ki, L. et al., "The Development of a 45% High Thermal Efficiency Engine," in 29th Aachen Colloquium Sustainable Mobility, 1043-1050, Aachen, Germany. (2020)
- ⁶⁷ Osborne, R., Lane, A., Turner, N., McWilliam, L. et al., "A New-Generation Lean Gasoline Engine for Reduced CO₂ in an Electrified World," in 40. Internationales Wiener Motorensymposium, Wien, Austria. (2019)
- ⁶⁸ Hamatani, T., Uehara, T., Akimoto, K., Hayashi, T., et al., "New Development of Hybrid System for Compact Car," 41. Internationales Wiener Motorensymposium, Wien, Austria. (2020) doi: 10.51202/9783186813121-II-1
- ⁶⁹ Tsurushima, T., Shiraishi, T., Tsuyuki, M., "Future Internal Combustion Engine Concept Dedicated to NISSAN e-POWER for Sustainable Mobility," 29th Aachen Colloquium Sustainable Mobility, Aachen, Germany. (2020)
- ⁷⁰ Egawa, T., Ushio, N., Kondo, T., Yamaguchi, R., et al., "Development of New 2.0 L I4 Gasoline Direct Injection Engine for Hybrid, " 31st Aachen Colloquium Sustainable Mobility, Aachen, Germany, Paper No. 09. (2022)
- ⁷¹ Scharf, J., Franzke, B., Adomeit, P., Thewes, M. et al., "200kW/L at Lambda = 1," in 40. Internationales Wiener Motorensymposium, Wien, Austria. (2019)
- ⁷² Kapus, P., Neubauer, M., Hilbert, D. Krenn, M., et al., "High Performance and Stoichiometric Operation—Wish or Reality?," in International Engine Congress, Baden-Baden, Germany. (2018)
- ⁷³ Glahn, C., Hermann, I., Kluin, M., and Koenigstein, A., "Technical Opportunities to Extend Stoichiometric Operation Area of Boosted Gasoline Engines in the High Volume Segment," in International Engine Congress, Baden-Baden, Germany. (2018)
- ⁷⁴ European Commission, "Proposal for a REGULATION OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL on type-approval of motor vehicles and engines and of systems, components and separate technical units intended for such vehicles, with respect to their emissions and battery durability (Euro 7) and repealing Regulations (EC) No 715/2007 and (EC) No 595/2009, " COM(2022) 586 final, Brussels, Belgium. (2022)
- ⁷⁵ Kawamura, Y., Shinshi, M., Sato, H., Takahashi, N. et al., "MBT Control through Individual Cylinder Pressure Detection, " SAE Technical Paper 881779. (1988) doi:10.4271/881779
- ⁷⁶ Takeuchi, M., Tsukada, K., Nonomura, Y., Omura, Y. et al., "A Combustion Pressure Sensor Utilizing Silicon Piezoresistive Effect, " SAE Technical Paper 930351. (1993) doi:10.4271/930351
- ⁷⁷ Shimasaki, Y., Kobayashi, M., Sakamoto, H., Ueno, M. et al., "Study on Engine Management System Using In-cylinder Pressure Sensor Integrated with Spark Plug, " SAE Technical Paper 2004-01-0519. (2004) doi:10.4271/2004-01-0519.
- ⁷⁸ Toth, D., Shaw, T., Wlodarczyk, M., and Cummings, C., "Cylinder Head Gasket with Integrated Combustion Pressure Sensors for Advanced Engine Controls, " SAE Int. J. Engines 4(1):p.1235-1246. (2011) doi:10.4271/2011-01-0938
- ⁷⁹ Romani, L., Lenzi, G., Ferrari, L., and Ferrara, G., "Indirect Estimation of In-Cylinder Pressure through the Stress Analysis of an Engine Stud, " SAE Technical Paper 2016-01-0814. (2016) doi:10.4271/2016-01-0814
- ⁸⁰ Nakai, E., Goto, T., Ezumi, K., Tsumura, Y., et al., "MAZDA SKYACTIV-X 2.0L Gasoline Engine, " 28th Aachen Colloquium Automobile and Engine Technology, p.55-78, Aachen, Germany. (2019)
- ⁸¹ Pauer, T., Weller, H., Schuenemann, E., Walther, J., et al., "A gasoline powertrain with negligible influence on air quality, " 41st Internationales Wiener Motorensymposium, Wien, Austria. (2020)
- ⁸² Rugland, C. and Stenlaas, O., "Knock Sensor Based Virtual Cylinder Pressure Sensor," SAE

Technical Paper 2019-01-0040. (2019) doi:10.4271/2019-01-0040

⁸³ Posch, S., Pirker, G., Kefalas, A., and Wimmer, A., "Development of a Virtual Sensor to Predict Cylinder Pressure Signal Based on a Knock Sensor Signal," SAE Technical Paper 2022-01-0627. (2022) doi:10.4271/2022-01-0627

⁸⁴ Liu, F., Amaratunga, G., Collings, N., and Soliman, A., "An Experimental Study on Engine Dynamics Model Based In-Cylinder Pressure Estimation, " SAE Technical Paper 2012-01-0896. (2012) doi:10.4271/2012-01-0896

⁸⁵ Aono, T., Saruwatari, M., Furuya, J., "Estimation of Engine Torque and Cylinder Pressure Index Based on Crankshaft Rotation Measurement, " 7th IFAC Symposium on Advances in Automotive Control, Volume 46, Issue 21, 2013, Pages 360-365, Tokyo, Japan. (2013) doi: 10.3182/20130904-4-JP-2042.00156

⁸⁶ Kulah, S., Donkers, T., and Willems, F., "Virtual Cylinder Pressure Sensor for Transient Operation in Heavy-Duty Engines, " SAE Int. J. Engines 8(3):p.1029-1040. (2015) doi:10.4271/2015-01-0872

⁸⁷ Yoneya, N., Aono, T., Saruwatari, M., "Combustion torque estimation from mass-produced crank angle sensor," 36th Chinese Control Conference, 2017, doi: 10.23919/ChiCC.2017.8028824

⁸⁸ Cavina, N., Poggio, L., and Sartoni, G., "Misfire and Partial Burn Detection based on Ion Current Measurement, " SAE Int. J. Engines 4(2):2451-2460. (2011) doi:10.4271/2011-24-0142

⁸⁹ Doi, K., Nakamura, Y., Hanashi, K., and Hashizume, K., "Development of Spark Plug for Ion Current Misfire Detection System, " SAE Int. J. Engines 5(3):p.1387-1393. (2012) doi:10.4271/2012-01-1253

⁹⁰ Shah, A., Tunestal, P., and Johansson, B., "Applicability of Ionization Current Sensing Technique with Plasma Jet Ignition Using Pre-Chamber Spark Plug in a Heavy Duty Natural Gas Engine, " SAE Technical Paper 2012-01-1632, (2012) doi:10.4271/2012-01-1632

⁹¹ Ogata, K., "Investigation of a Detecting Technology of Combustion Conditions Using the Ion-Current Sensor, " SAE Technical Paper 2015-01-1983. (2015) doi:10.4271/2015-01-1983

⁹² Kusuhara, T., Shinkai, T., Yoshida, K., Langley, D. et al., "Development on Internal EGR Feedback Control Based on Ion Current, " SAE Technical Paper 2017-01-0793. (2017) doi:10.4271/2017-01-0793

⁹³ Kengo, K., Kimura, H., Akagi, Y., Matohara, S., et al., "Enhancement of knocking detection accuracy by an ion-current sensor integrated in the ignition system, " Journal of Thermal Science and Technology, Volume 16(2021) Issue 3, JTST0037. (2021) doi: 10.1299/jtst.2021jtst0037

⁹⁴ Angeby, J., "Spark Ignition System for Alternative Fuels – Robust Ignition, Minimized Spark Plug Wear and Combustion, " in 8th International Engine Congress, Baden-Baden, Germany. (2021)

⁹⁵ Shiraishi, T., Maeda, H., Noguchi, M., "Ignition device and ignition method for internal combustion engine, " Japan patent, JP6357985B2. (2018)

⁹⁶ Shikata, Y., Tanaka, D., Uchida, R., Iwabuchi, Y., "Control device and control method for direct injection engine, " Japan patent, JP6717671B2. (2020)

⁹⁷ Funato, I., Sugiura, A., Terada, K., "Ignition control device, " United States Patent, US 11, 199, 170 B2. (2021)

⁹⁸ Bellone, M., Faghani, E., and Karayiannidis, Y., "Comparison of CNN and LSTM for Modeling Virtual Sensors in an Engine," SAE Int. J. Advances & Curr. Prac. in Mobility 2(5):p.2632-2639. (2020) doi:10.4271/2020-01-0735.

⁹⁹ Hanuschkin, A., Zuendorf, S., Schmidt, M., Welch, C., et al, "Investigation of cycle-to-cycle variations in a spark-ignition engine based on a machine learning analysis of the early flame kernel, " Proceedings of the Combustion Institute Volume 38, Issue 4, 2021, Pages p.5751-5759 (2021)

¹⁰⁰ Johnson, R., Kaczynski, D., Zeng, W., Warey, A. et al., "Prediction of Combustion Phasing Using

Deep Convolutional Neural Networks,” SAE Technical Paper 2020-01-0292, (2020)

doi:10.4271/2020-01-0292

¹⁰¹ Warey, A., Gao, J., and Grover, R., “Prediction of Engine-Out Emissions Using Deep Convolutional Neural Networks,” SAE Int. J. Advances & Curr. Prac. in Mobility 3(6):2863-2871. (2021) doi:10.4271/2021-01-0414

¹⁰² Frändberg, S., “Fuel degradation in vented PHEV fuel tanks,” Master’s thesis of Chalmers University of Technology. (2016)

¹⁰³ Mokros, A., Beidl, C., “OME in the diesel engine – a concept for CO₂ neutrality and lowest pollutant emissions,” 5th International Engine Congress. (2018)

¹⁰⁴ K. Gaukel, et al., “Combustion process optimization for OME fuels in a heavy-duty application,” 6th International Engine Congress Baden-Baden. (2019)

¹⁰⁵ Blochum, S., Fellner, F., Mühlthaler, M., Härtl, M. et al., “Comparison of Promising Sustainable C1-Fuels Methanol, Dimethyl Carbonate, and Methyl Formate in a DISI Single-Cylinder Light Vehicle Gasoline Engine,” SAE Technical Paper 2021-01-1204. (2021) doi:10.4271/2021-01-1204

¹⁰⁶ Kraus, C., Jakubec, P., Girhe, S., Fellner, F. et al., “Adaptation and Engine Validation of an FTIR Exhaust Gas Analysis Method for C1-Based Potential GHG-Neutral Synthetic Fuels/Gasoline-Blends Containing Dimethyl Carbonate and Methyl Formate,” SAE Technical Paper 2022-01-0569. (2022) doi:10.4271/2022-01-0569.

¹⁰⁷ Demuynck, J., Mendoza Villafuerte, P., Bosteels, D., Kuhrt, A. et al., “Advanced Emission Controls and E-fuels on a Gasoline Car for Zero-Impact Emissions,” SAE Technical Paper 2022-01-1014. (2022) doi:10.4271/2022-01-1014.

¹⁰⁸ Larsson, T., Stenlaas, O., and Erlandsson, A., “Future Fuels for DISI Engines: A Review on Oxygenated, Liquid Biofuels,” SAE Technical Paper 2019-01-0036. (2019) doi:10.4271/2019-01-0036

¹⁰⁹ Farhrenbruch, A., Bachmann, J., “Ethanol Sensors for Flex Fuel Operation,” MTZ Worldwide 09 | 2008 Volume 69, p46-49. (2008)

¹¹⁰ Oliverio, N., Stefanopoulou, A., Jiang, L., and Yilmaz, H., “Ethanol Detection in Flex-Fuel Direct Injection Engines Using In-Cylinder Pressure Measurements,” SAE Int. J. Fuels Lubr. 2(1):229-241. (2009) doi:10.4271/2009-01-0657

¹¹¹ Ahn, K., Stefanopoulou, A., Jankovic, M., “AFR-Based Fuel Ethanol Content Estimation in Flex-Fuel Engines Tolerant to MAF Sensor Drifts,” IEEE TRANSACTIONS ON CONTROL SYSTEMS TECHNOLOGY, VOL. 21, NO. 3. (2013)

¹¹² Bertolini, L., Redaelli, E., “Throwing power of cathodic prevention applied by means of sacrificial anodes to partially submerged marine reinforced concrete piles: Results of numerical simulations,” Corrosion Science, 51 [9] p.2218-2230. (2009)

¹¹³ Parsa, H., M., Allahkaram, R., S., and Ghobadi, H., A., “Simulation of cathodic protection potential distributions on oil well casings,” Journal of Petroleum Science and Engineering, 72, p.215-219. (2010)

¹¹⁴ Matsuoka, K., Yamamoto, M., and Goto, K., “Analysis for Macro-cell Corrosion Phenomena of Steels Exposed in Sea Water,” Zairyo-to-Kankyo, 56, p.99-105. (2007)

¹¹⁵ Kitagawa, T., Tamada, A., Wakana, H., Todorobaru, M., et al., “Characteristic of Cathodic Current in Tidal Zone of Cathodically Protected Marine Steel Structure in the Ocean,” Zairyo-to-Kankyo, 54, p.288-294. (2005)

¹¹⁶ 審良 善和, 山路 徹, 小林 浩之, 渡部 要一, 他, “海底土中部における防食電流密度と土質特性の関係,” 第 59 回材料と環境討論会予稿集, p.253, 社団法人腐食防食協会. (2012)

¹¹⁷ Uchibori, T., “Key Points on Design of Cathodic Protection System,” Corrosion Engineering, 37, p.685-691. (1988)

¹¹⁸ 笠原 太郎, 渡部 光, 池田 太一, 吉越 洋志, “深層学習によるエンジン放射音からのノッキング音と

筒内圧の推定手法（第4報），”自動車技術会論文集, Vol.52, No.2, p.263-268. (2021)

¹¹⁹ Ren, P., Xiao, Y., Chang, X., Huang, P., et al., “A Survey of Deep Active Learning,” ACM Computing Surveys (CSUR), 54, 1 - 40. (2022)

¹²⁰ 斎藤 達哉, 天谷 賢治, "データ同化を用いた電気防食モニタリング手法の開発," 「材料」 0514-5163, 公益社団法人 日本材料学会, 2020 69 11, p.783-788. (2020)

¹²¹ Bernhard, M., “From E-Fuel to E-Mobility – Innovative powertrain strategies,” Fuels of the future 2019, Berlin. (2019)

¹²² Kai Zhao, “A Brief Review of China’s Methanol Vehicle Pilot and Policy,” <https://www.methanol.org/wp-content/uploads/2019/03/A-Brief-Review-of-Chinas-Methanol-Vehicle-Pilot-and-Policy-20-March-2019.pdf> (2019) Referred on June 1st, 2023)

¹²³ Dolan, G., “Overview of Global Methanol Fuel Blending,” Trinidad and Tobago Methanol Fuel Blending Forum. (2019)

¹²⁴ Wagner, C., Grill, M., Keskin, M., Bargende, M. et al., "Potential Analysis and Virtual Development of SI Engines Operated with Synthetic Fuel DMC+, " SAE Technical Paper 2020-01-0342. (2020) <https://doi.org/10.4271/2020-01-0342>.

謝辞

本研究に取り組むにあたり、指導教員の天谷賢治教授から丁寧かつ熱心なご指導を頂きました。ここに感謝の意を表します。

本論文の審査過程において数々のご助言を賜りました、システム制御コースの小酒英範教授、田中正行教授、佐藤進准教授、宮崎祐介准教授に深謝申し上げます。

大西有希助教には、有限要素法モデル作成やプログラムについて様々なご指導をいただき、常に快適な環境で効率的な研究を行うことができました。深く感謝いたします。

海洋鋼構造物の電気防食に関する共同研究においては、田代賢吉様、飯田知宏様、斎藤達哉様をはじめとする日本防蝕工業株式会社の皆様、また鹿児島大学の審良善和様、独立行政法人港湾空港技術研究所の山路徹様に多大なご支援を賜りました。深く御礼申し上げます。

自動車エンジンに関する研究においては、株式会社日立製作所研究開発グループの熊野賢吾様、助川義寛様、島田敦史様、小祝隆太郎様、日立 Astemo 阪神株式会社の内勢義文様、藤山幸雄様、実英男様、日立 Astemo 株式会社の白石拓也様、岡本多加志様、鈴木邦彦様より、ご指導、ご協力を頂きました。ここに感謝申し上げます。

皆様のご協力があり、本論文を執筆することができました。まことにありがとうございました。

2023 年 8 月 吉日