

超臨界地熱発電技術研究開発／超臨界地熱
資源への調査井掘削に資する革新的技術開
発／AIによる超臨界地熱資源評価・掘削技術

【資源評価技術】

(国研)産業技術総合研究所

(国)室蘭工業大学

(国)東北大学

(国)京都大学

(国)九州大学

地熱エンジニアリング(株)

(国)北海道大学(再委託)

(国)東京工業大学(再委託)

問い合わせ先

産業技術総合研究所山谷祐介

E-mail: y.yamaya@aist.go.jp

TEL: 029(861)4114

【掘削技術】

地熱技術開発(株)

(国)秋田大学

帝石削井工業(株)

(株)物理計測コンサルタント

問い合わせ先

地熱技術開発(株)大里和己

E-mail: osato@gerd.co.jp

TEL: 03(5541)9072

事業概要

AIによる超臨界地熱資源評価技術

1. 期間

開始 : 2018年8月

終了 : 2021年2月

2. 最終目標

* 水の超臨界状態相当の温度実測値が存在するフィールドにおいて、当該実測値を除いたデータを使用してAIが推定した温度構造と当該実測値の残差が20%以内であること。

3. 成果概要

* 開発手法の妥当性評価: 貯留層シミュレーションモデルに基づくデータセットを用いて、予測温度の評価を行い、広域で坑井数の多い条件下ではいずれも20%以下の誤差。

* 実データの適用(ベイズ推定): 岩石物理モデルに基づくベイズ推定により、葛根田地域の浅部坑井温度ならびに伝導域を含む深部坑井温度を十分な精度(13.9%)で再現可能。

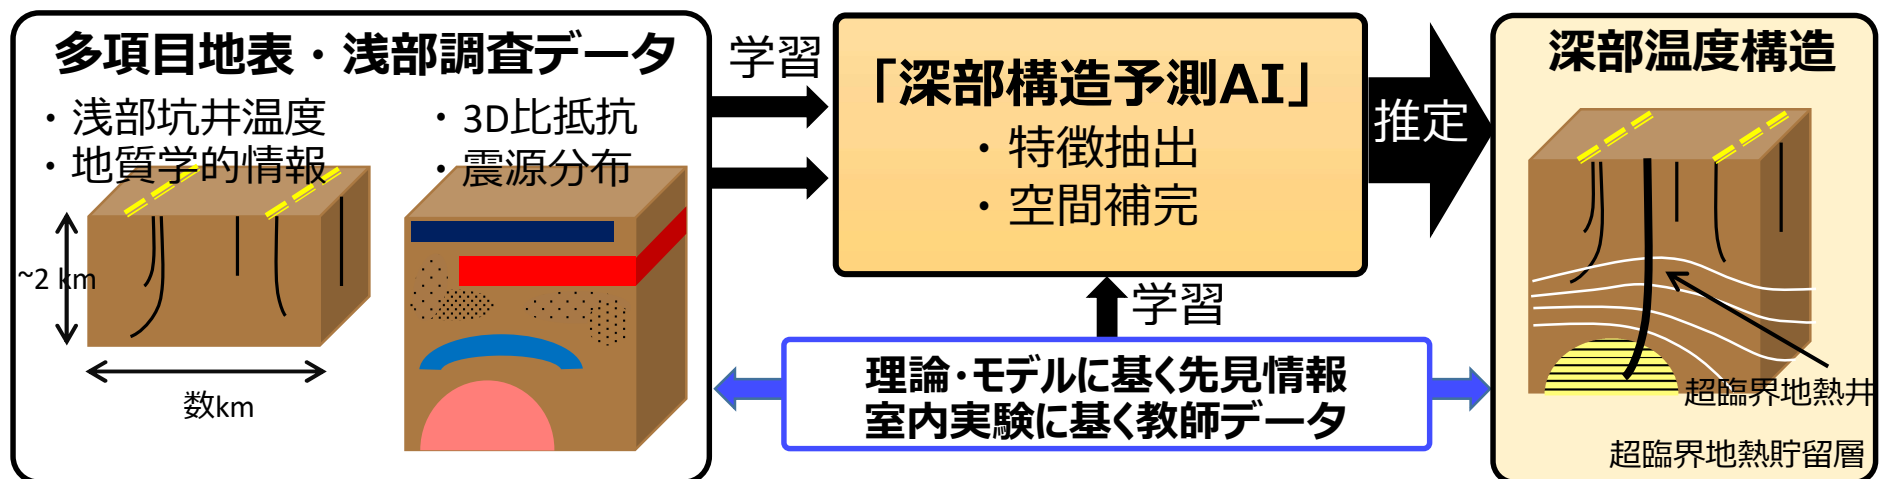
* 実データの適用(ニューラルネット): 深部の伝導領域の温度上昇予測は困難、対流-伝導境界の温度(380~400℃)は許容内の誤差(約14~16%)で推定可能。

* 人工データの学習による一般化の試み: 人工データセットをニューラルネットワークで学習し、貯留層シミュレーションモデルに基づくデータセットで予測温度の評価を行った。現在の学習法では、D95深度を加えることで伝導域の温度も精度よく推定できる可能性示唆。

背景・課題

AIによる超臨界地熱資源評価技術

- * 地熱掘削ターゲットの決定手法 = 各種データを収集し、総合解析により地下温度、透水性構造を推定することであるが、データ解釈の標準規格は存在しない。また、直接的な地下情報 = 検層による1次元データであり、空間的広がりや坑底以深の情報は得られない。これらの理由により、従来型の地熱開発でも掘削ターゲットの決定は容易でなく、掘削コストがかさむ原因になっている。
- * 超臨界地熱開発では未知の深さ・温度を対象とすることから、掘削ターゲットを高精度で決定し、掘削コストを低減させることが必須である。
- * 本PJでは、坑井データと地表で得られるデータから、超臨界地熱資源の特定に重要な深部の温度構造を、人工知能技術（AI）を使って自動的かつ定量的に推定する技術の開発を行う。



本PJ実施内容概念図

開発目標

AIによる超臨界地熱資源評価技術

最終目標（2021年2月末）

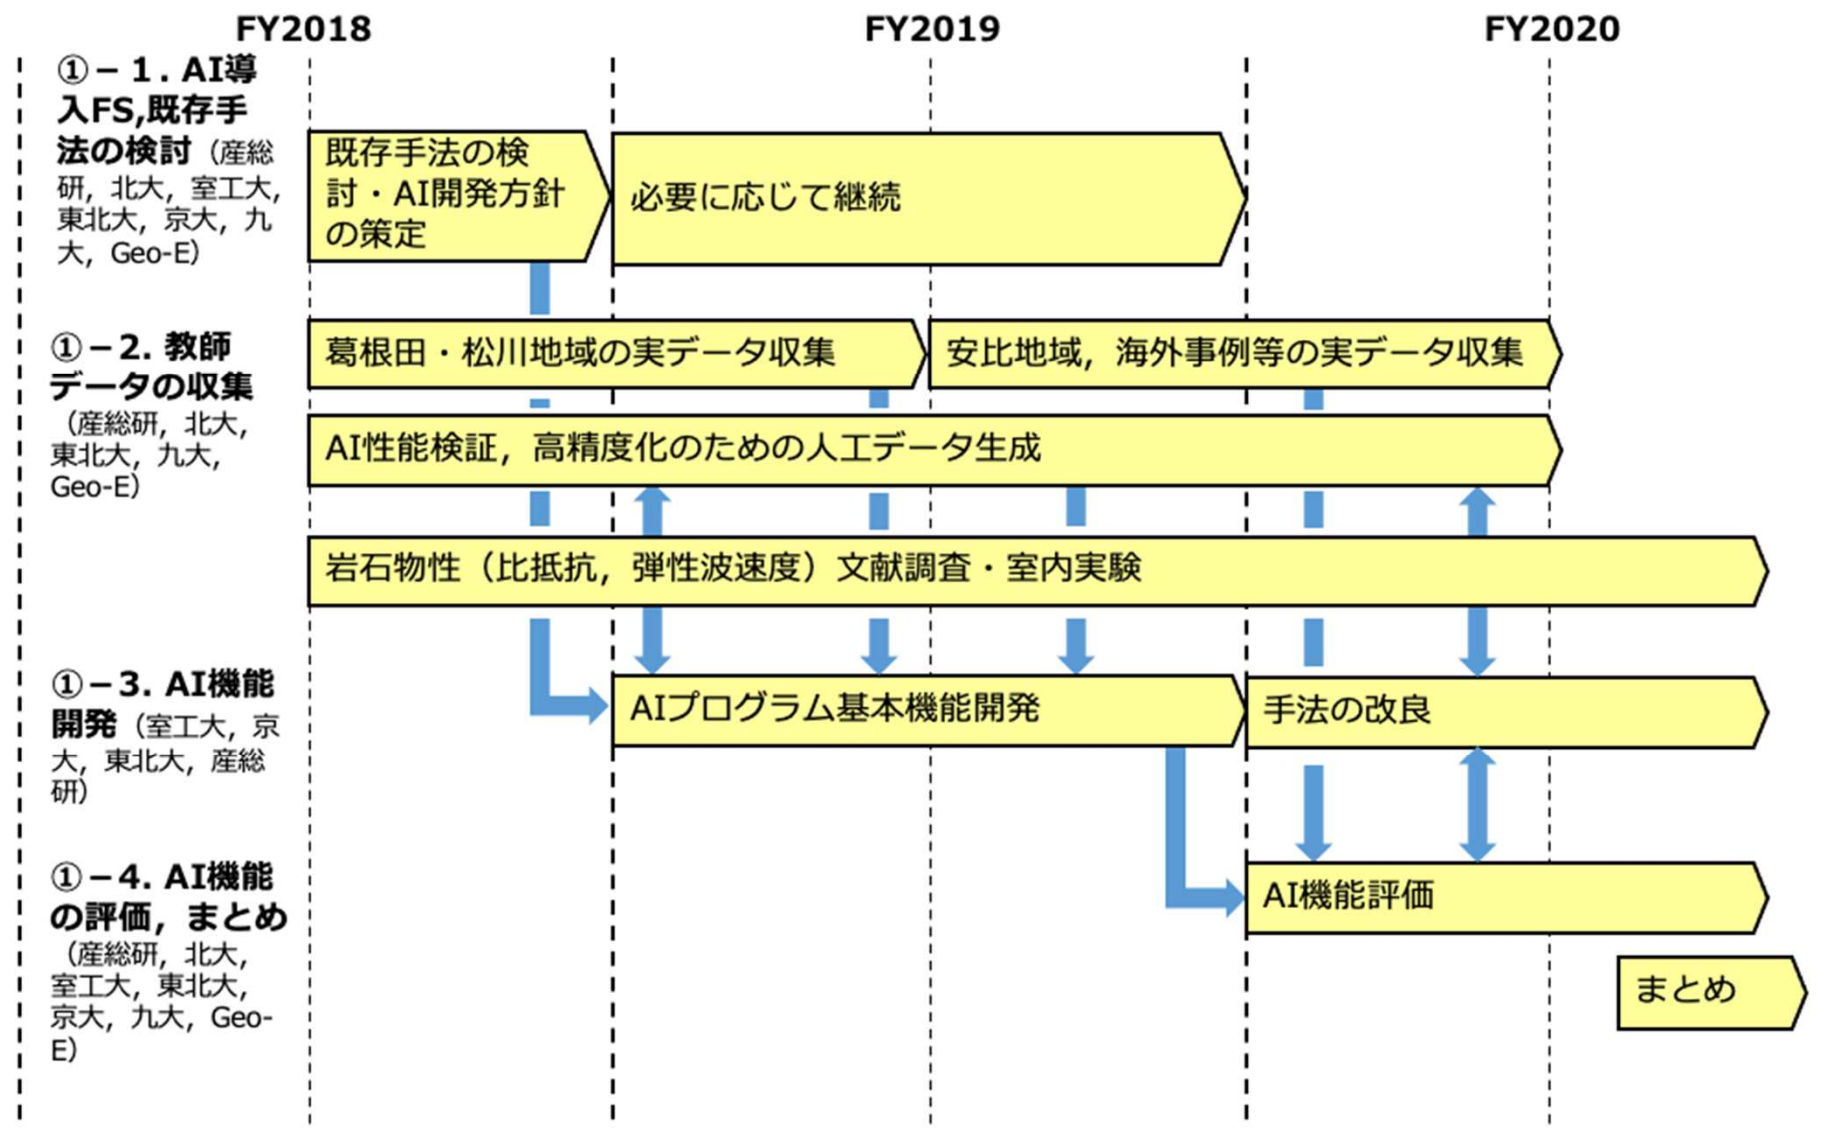
- * 水の超臨界状態相当の温度実測値が存在するフィールドにおいて，当該実測値を除いたデータを使用して AI が推定した温度構造と当該実測値の残差が20%以内であること。

設定理由：

既存機械学習的手法による推定誤差を改善し，定量的かつ自動的な地下温度構造の推定を実現するため。

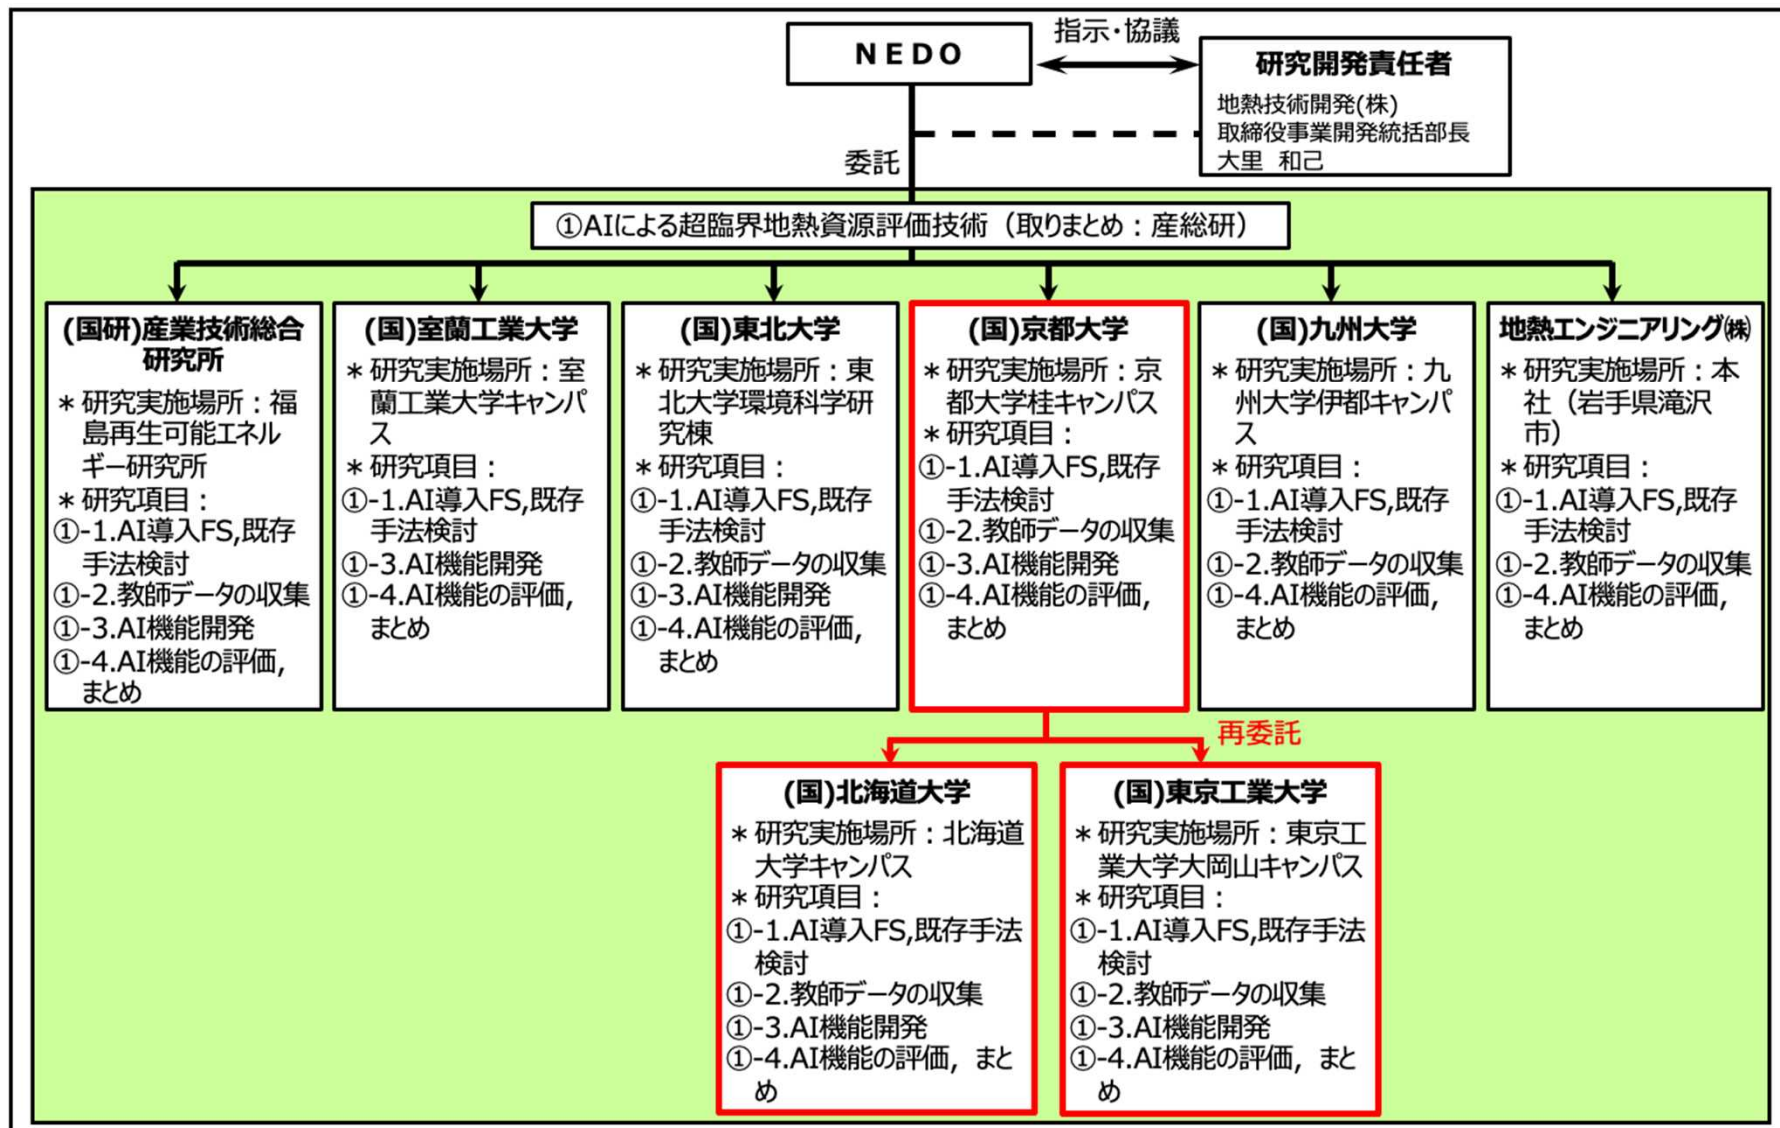
開発スケジュール

AIによる超臨界地熱資源評価技術



実施体制

AIによる超臨界地熱資源評価技術

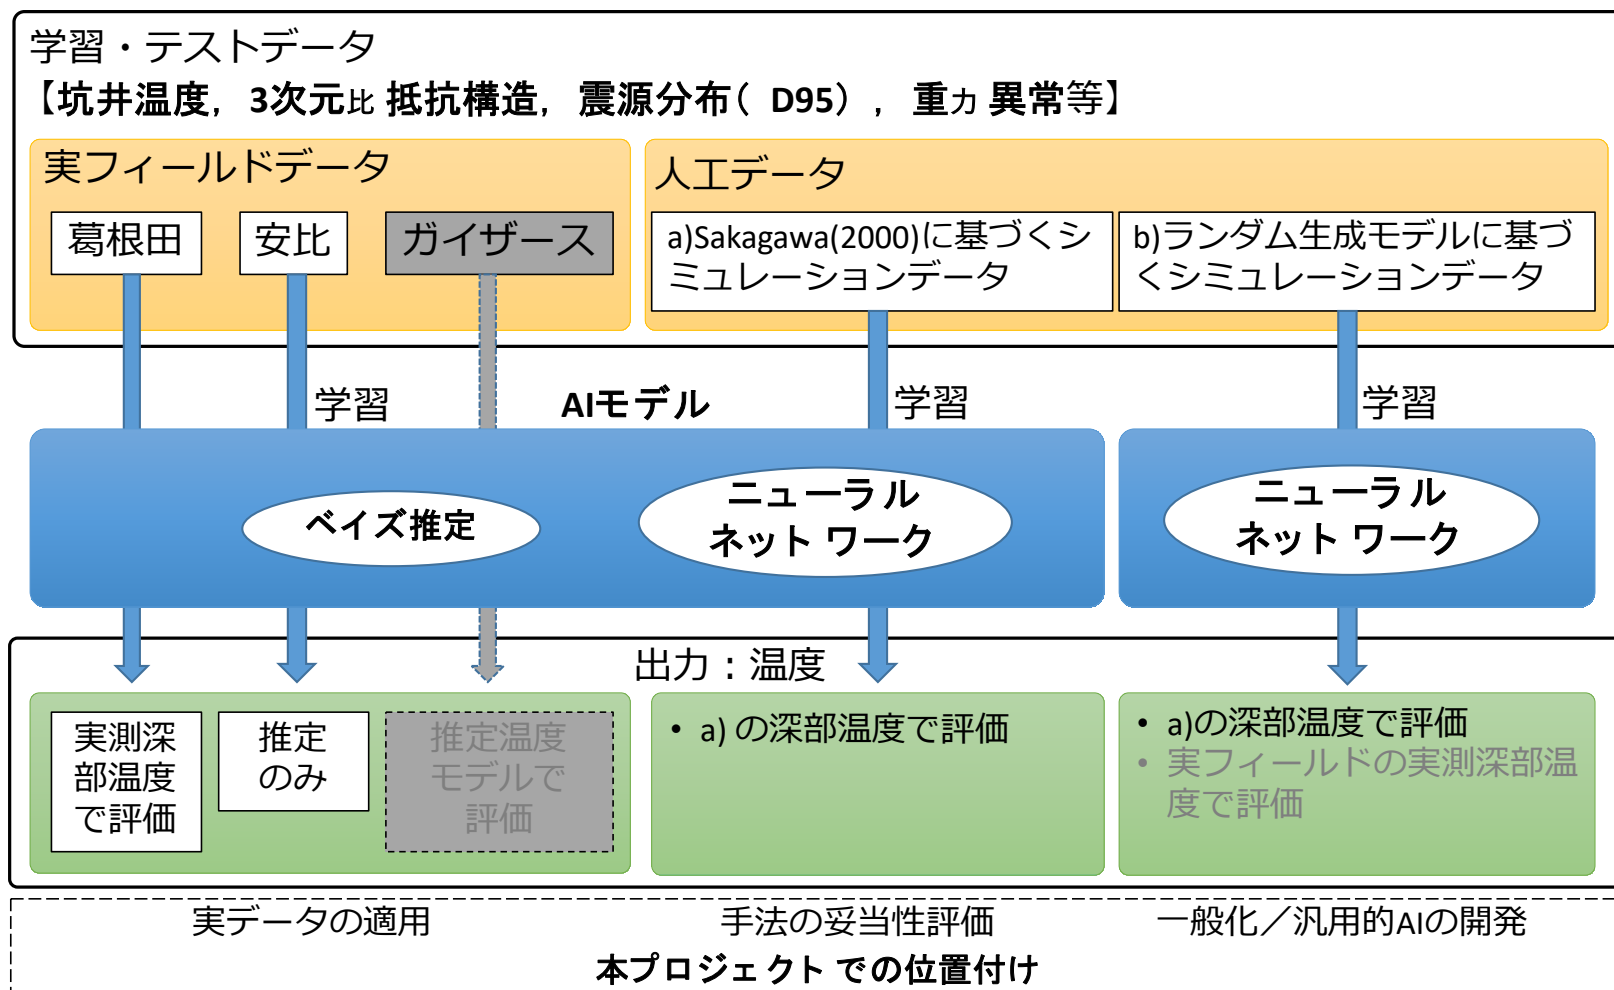


成果例

AIによる超臨界地熱資源評価技術

教師データの収集

収集したデータと使途




成果例

AIによる超臨界地熱資源評価技術

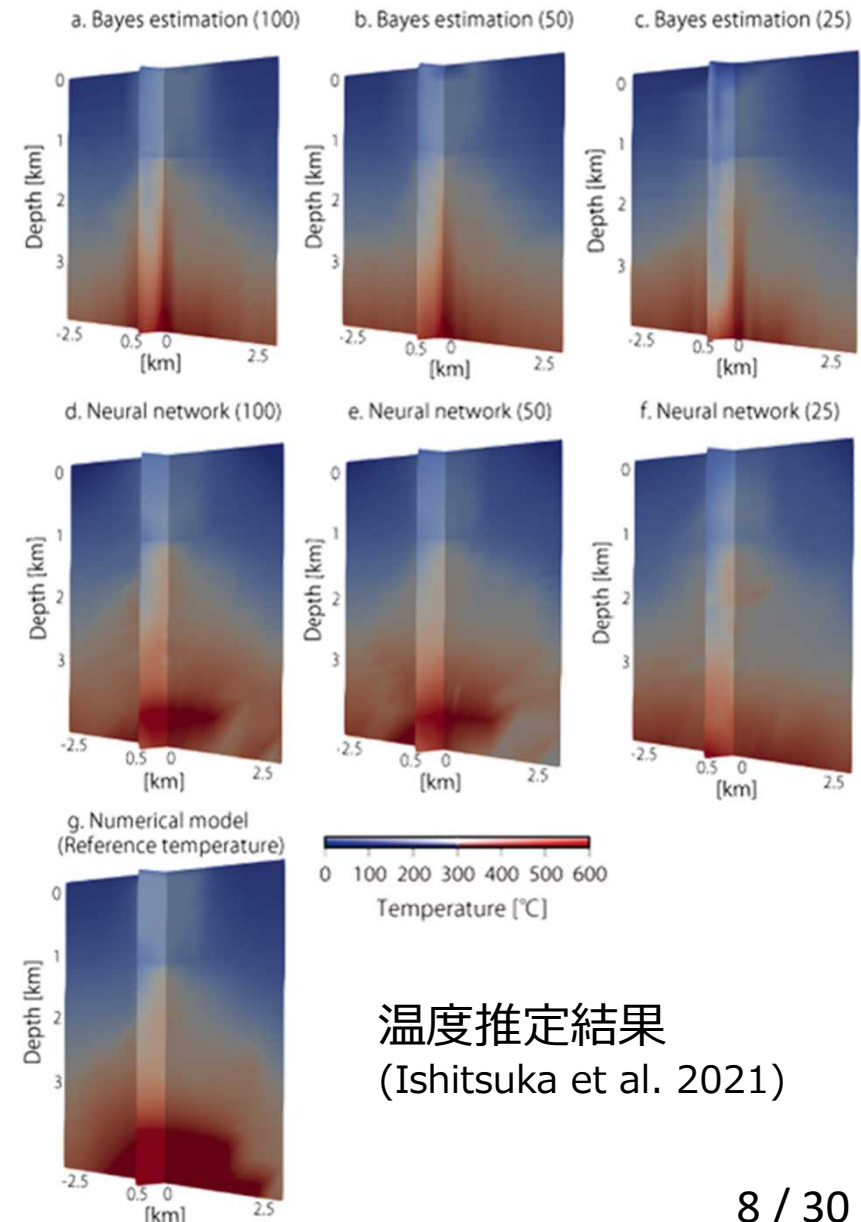
開発したニューラルネットワークおよび ベイズ推定の妥当性検証

葛根田地熱地域の数値シミュレーション (Sakagawa et al. 2000) による温度構造を利用し、誤差の検証を行った。



検証した領域(Ishitsuka et al. 2021)

- ニューラルネットワーク、ベイズ推定ともに、井戸データ数や位置により、約8-20 %の誤差で推定できることが示された。


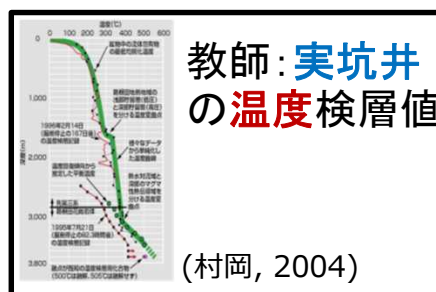
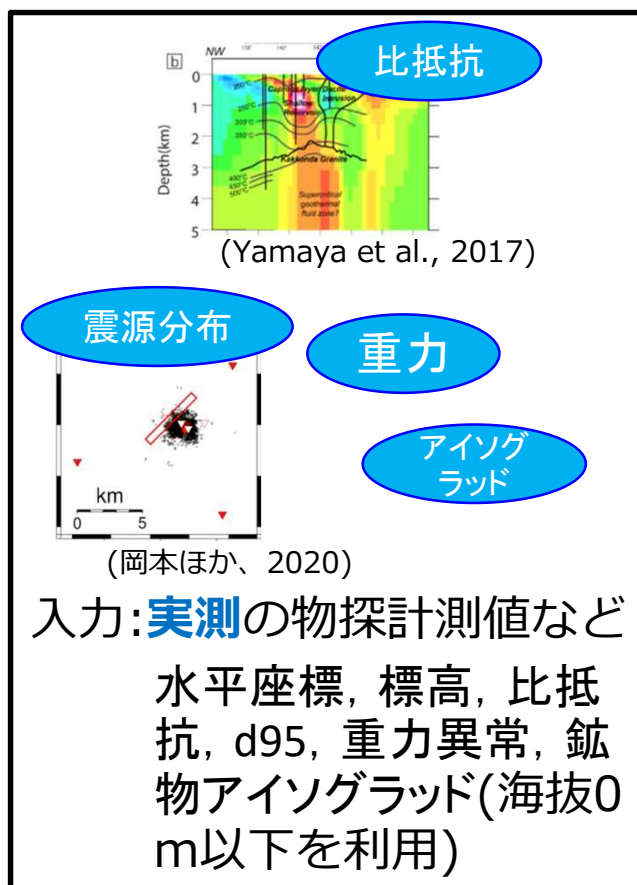


温度推定結果
(Ishitsuka et al. 2021)



成果例

AIによる超臨界地熱資源評価技術

実フィールドデータへの適用 ニューラルネットの例



出力



- ニューラルネットワークでは14~16%、ベイズ推定では約14%の誤差で深部380度以上の温度を再現可能であることが示された。

成果例

AIによる超臨界地熱資源評価技術

AI機能評価まとめ

入力データの条件と推定結果への影響

| データ 手法 | 既存坑井数 | 既存坑井深さ | 岩石、間隙水物性データ | 物理探査データ |
|--------------|--|---|--|---|
| ニューラル ネット | <ul style="list-style-type: none"> 貯留層全体をカバーする広域では数十坑井必要。 深部構造が似ている狭い範囲のみの推定では、坑井数の影響は少ない。 | <ul style="list-style-type: none"> 影響が大きく、ターゲットに近い深さが必要。 実データのみ学習の場合、比抵抗変化に対応する深部坑井温度が必須。人工データセットにより改善の可能性あり。 | <ul style="list-style-type: none"> 不要。 | <ul style="list-style-type: none"> 3次元比抵抗 深部高温の推定には震源分布（D95）が必須 浅部温度分布の推定に重力異常が効果的な場合あり。 |
| ベイズ推定 | <ul style="list-style-type: none"> 坑井数の影響は比較的少ないが、解析対象の水平範囲をカバーする領域に分布していることが好ましい。 | <ul style="list-style-type: none"> 影響が大きく、ターゲットに近い深さが必要。 | <ul style="list-style-type: none"> 岩石の比抵抗、空隙率、塩濃度のデータにより精度向上。 別モデルの導入により浸透率等も考慮可能。 | <ul style="list-style-type: none"> 3次元比抵抗のみ |

成果例

AIによる超臨界地熱資源評価技術

AI機能評価まとめ

* 開発手法の妥当性評価

貯留層シミュレーションモデルに基づくデータセットを用いて、予測温度の評価を行った。広域で坑井数の多い条件下ではいずれも20%以下の誤差となった。一方、局所的で坑井数が少ない条件下では、既存坑井の深さが推定誤差に大きく影響することが明らかになった。

* 実データの適用（ベイズ推定）

岩石物理モデルに基づくベイズ推定により、葛根田地域の浅部坑井温度ならびに伝導域を含む深部坑井温度を十分な精度（13.9%）で再現可能であることを示した。

* 実データの適用（ニューラルネット）

深部の伝導領域の温度上昇予測は困難であるものの、対流－伝導境界の温度（380～400℃）は許容内の誤差（約14～16%）で推定できることが明らかとなった。また、坑井分布が等方的であること、微小地震データの使用が予測精度向上に寄与する可能性が示された。

* 人工データの学習による一般化の試み

人工データセットをニューラルネットワークで学習し、貯留層シミュレーションモデルに基づくデータセットで予測温度の評価を行った。現在の学習法では、水平座標を考慮できないが、D95深度を加えることで伝導域の温度も精度よく推定できる可能性が示唆された。

目標達成状況

AIによる超臨界地熱資源評価技術

| 開発項目 | 開発目標 | 成果 | 達成 |
|-------------------|---|---|---|
| ①AIによる超臨界地熱資源評価技術 | <ul style="list-style-type: none"> 水の超臨界状態相当の温度実測値が存在するフィールドにおいて、当該実測値を除いたデータを使用してAIが推定した温度構造と当該実測値の残差が20%以内であること。 | <ul style="list-style-type: none"> 水の超臨界状態相当の温度実測値が存在するフィールド（葛根田地域）において、当該実測値を除いたデータを使用してAIが推定した温度構造と当該実測値の残差は、ベイズ推定で13.9%、ニューラルネットワークで14～16%となった。 | <ul style="list-style-type: none"> ○ |

実用化の見通し

[AIによる超臨界地熱資源評価技術](#)

- 本事業を通して、AIは当該実測値の20%以内の誤差で水の超臨界相当の温度を推定可能であることが示された。今後、学習方法の改善、物理モデルの精緻化により推定の高精度化を進める。有望地点におけるパイロット孔掘削、詳細な地質、物理探査による実測データで実証し、本掘削地点の選定前の事業化を目指す。

実用化にむけた課題・取組

[AIによる超臨界地熱資源評価技術](#)

課題

- 現状として温度実測値の少ない深部超臨界領域の学習データが相当数必要。特に、対流－伝導境界で温度勾配が変曲し、超臨界領域に達する場合、伝導条件での学習データが存在しないケースが多いため、温度変曲の再現が困難。

取組

- 人工データによる実測データの補完、学習データの水増しを行う方法を確立する。
- より低温の条件で対流－伝導境界を含む実データでの予測技術を完成し、超臨界域への適用を実施する。

事業概要

AIによる超臨界地熱資源掘削技術

1. 期間

開始 : 2018年8月

終了 : 2021年2月

2. 最終目標

AI による超臨界地熱資源掘削技術として、既存のマッドロギングとオープンソースAI ソフトウェアをベースとすることで、低い運用コストで実現するビット摩耗度の予測とそれに伴うリスクの評価を行う掘削アシスト型AI システムの開発を行う。過去に得られたマッドロギングデータを入力して、ビットの摩耗度の予測を行い、現実の計測数値と誤差20%以内の精度での予測を行うことが可能なこと。

3. 成果概要


- 全体システム設計: 実装するシステムの基本設計、クラウド上のシステム構築等
- 掘削現象の体系化: 様々な掘削事例の体系化とまとめ、ロータリーモード時・スライドモード時の掘削寿命判定に有効な掘削パラメータの抽出、教師・試験データの整備等
- センサ技術: 回転トルク計測法の規準化、機械学習へ引き渡すデータの品質向上等
- 機械学習技術: オートエンコーダNNに基づくビット寿命予測アルゴリズムの開発、K-近傍法に基づくビット寿命予測アルゴリズムの開発、Shapeletsによるビット寿命判定アルゴリズムの開発により、損傷ビットと正常ビットの評価で88.9%の正答率を得た。

背景・課題

AIによる超臨界地熱資源掘削技術

機械学習によりローラーコーンビットの損傷を予測する

- 超臨界地熱井などの掘進長4,000mを超える大深度坑井におけるビット交換のための揚降管作業時間（掘削停止期間）の増大＝掘削コスト増大。超臨界地熱井では、高温・硬質岩での掘削が予想され、ビット損傷によるコーン落下などの事故の可能性が増すため、より安全な使用時間で交換を行うため、掘削コストは更に増大することから、ビットの寿命を予測することはコスト削減に寄与。
- ビットは消耗品なので新品からビット損傷直前までの寿命を予測する。
- 長く使うほど、経済性が改善されるが、ビット損傷によるコーン落下のリスクが増加する。
- ローラーコーンビットは、ベアリングの損傷によるガタツキや掘進率の減少などが予想される。コーンが脱落しない限り、多少のベアリング損傷であれば、掘削継続は可能であるのでビットの摩耗度ではなく、ベアリング（回転機械）の寿命を予測の中心とする方が現実的である。
- 使用開始時点では新品＝正常であることから、使用開始時点を正常値としてその時点からのズレを検知して損傷を予想する「外れ値検知」アルゴリズムが適用できる。
- なお、回転部分が存在しないPDCビットについては、地熱での適用事例が少ないため、次期課題とする。



開発目標(2020年度末)

過去に得られたマッドロギング等を入力して、ビットの摩耗度(損耗度)の予測を行い、現実の計測数値と20%以内の精度で予測

開発目標

AIによる超臨界地熱資源掘削技術

最終目標（2021年2月末）

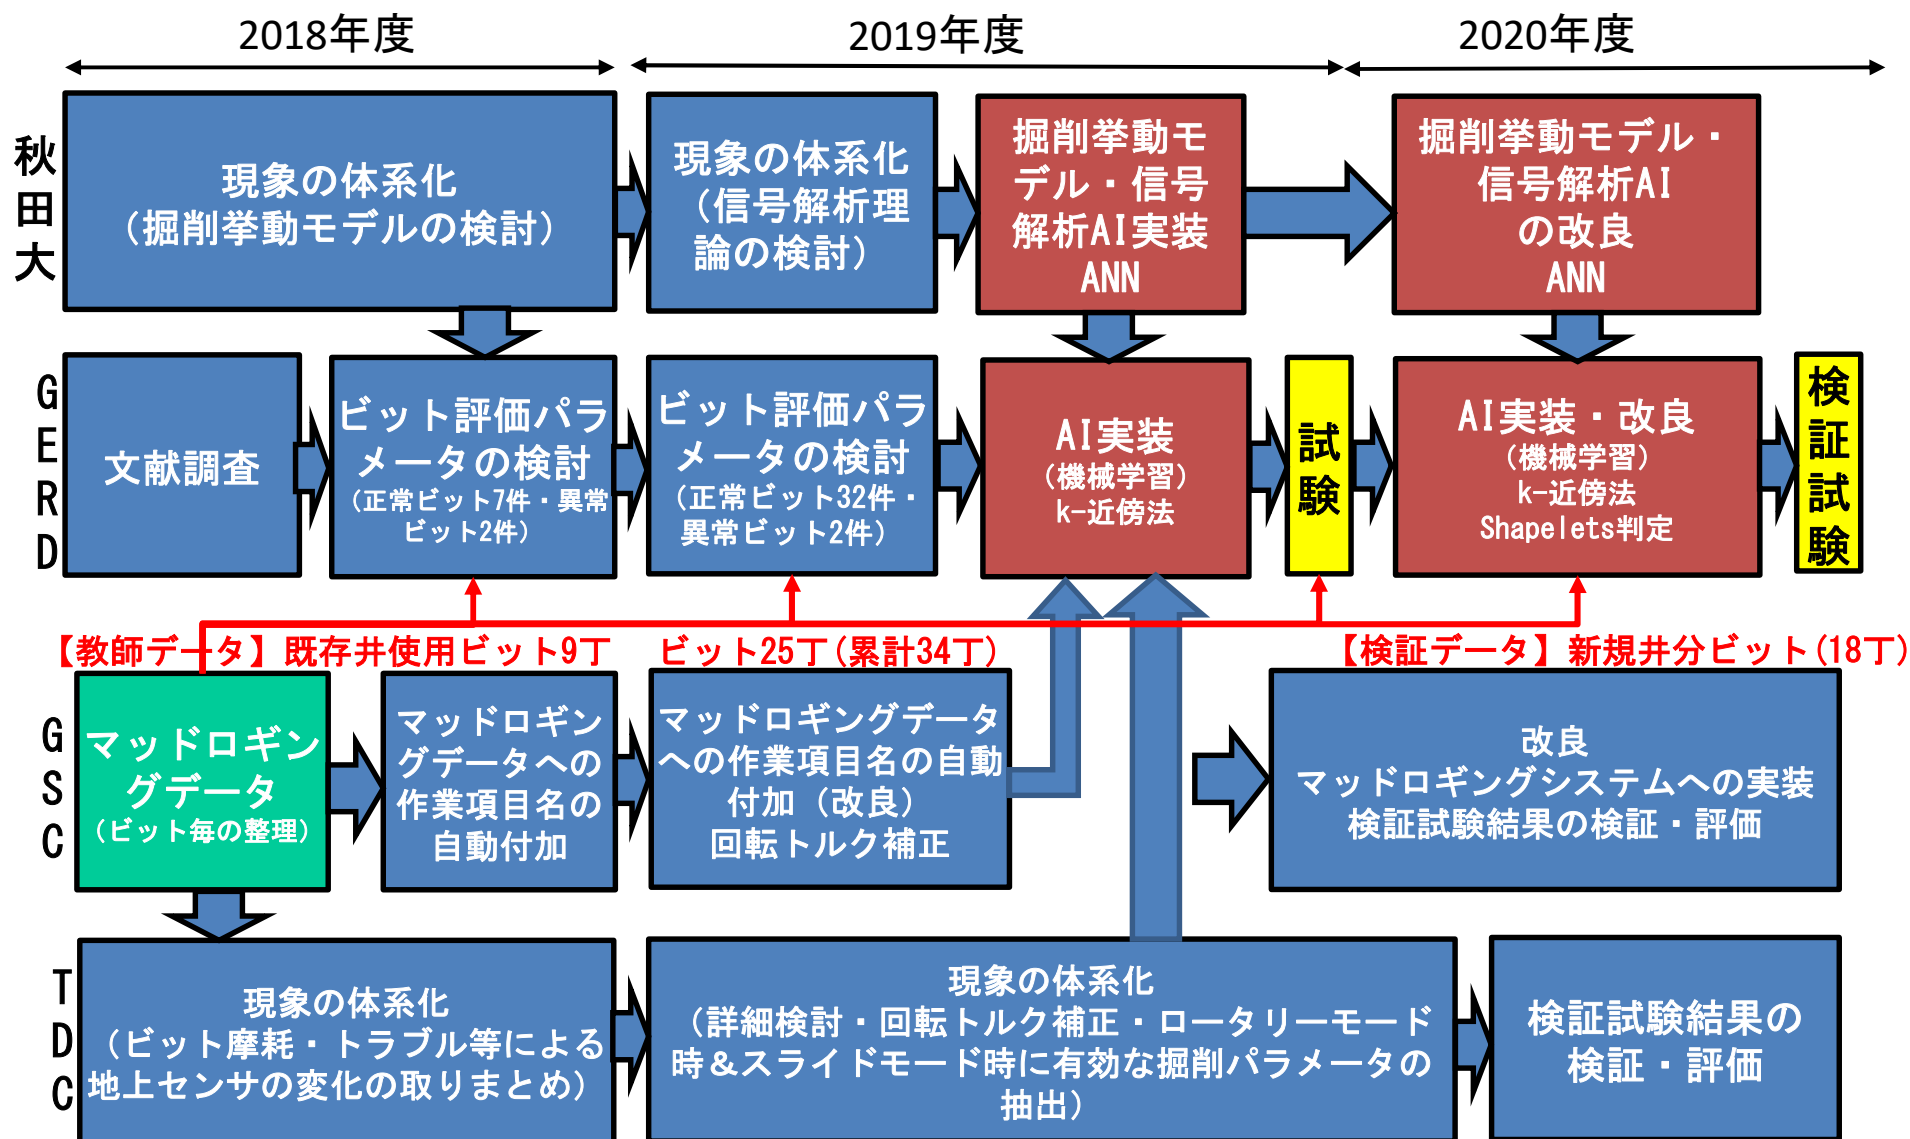
- * 過去に得られたマッドロギングデータを入力して、ビットの摩耗度の予測を行い、現実の計測数値と誤差20%以内の精度での予測を行うことが可能なこと。

設定理由：

現場の経験則から20%程度の予測誤差であれば実用に供するため。

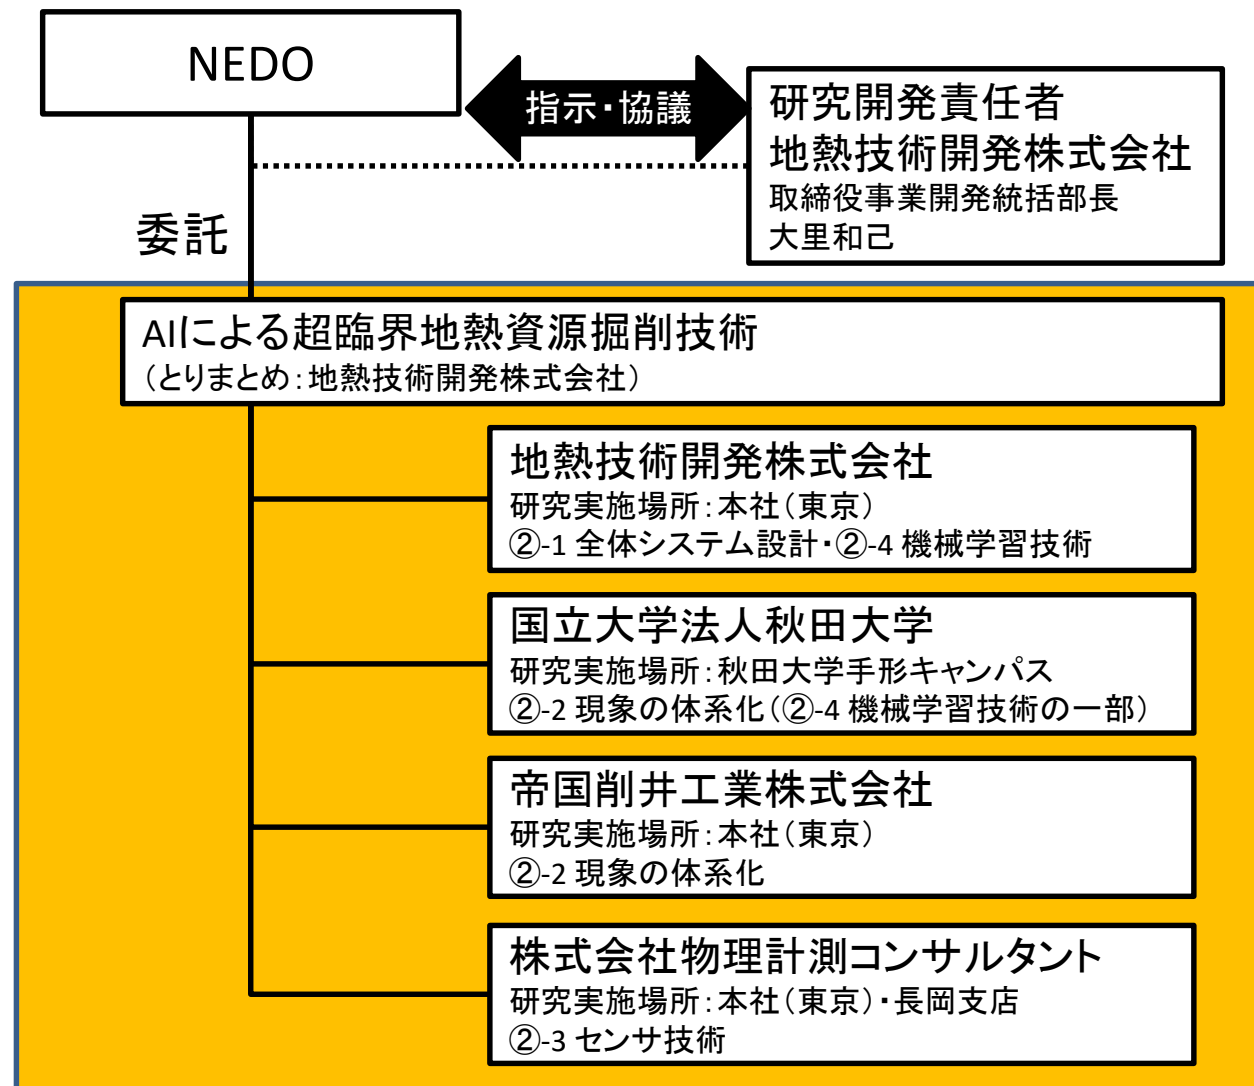
開発スケジュール

AIによる超臨界地熱資源掘削技術



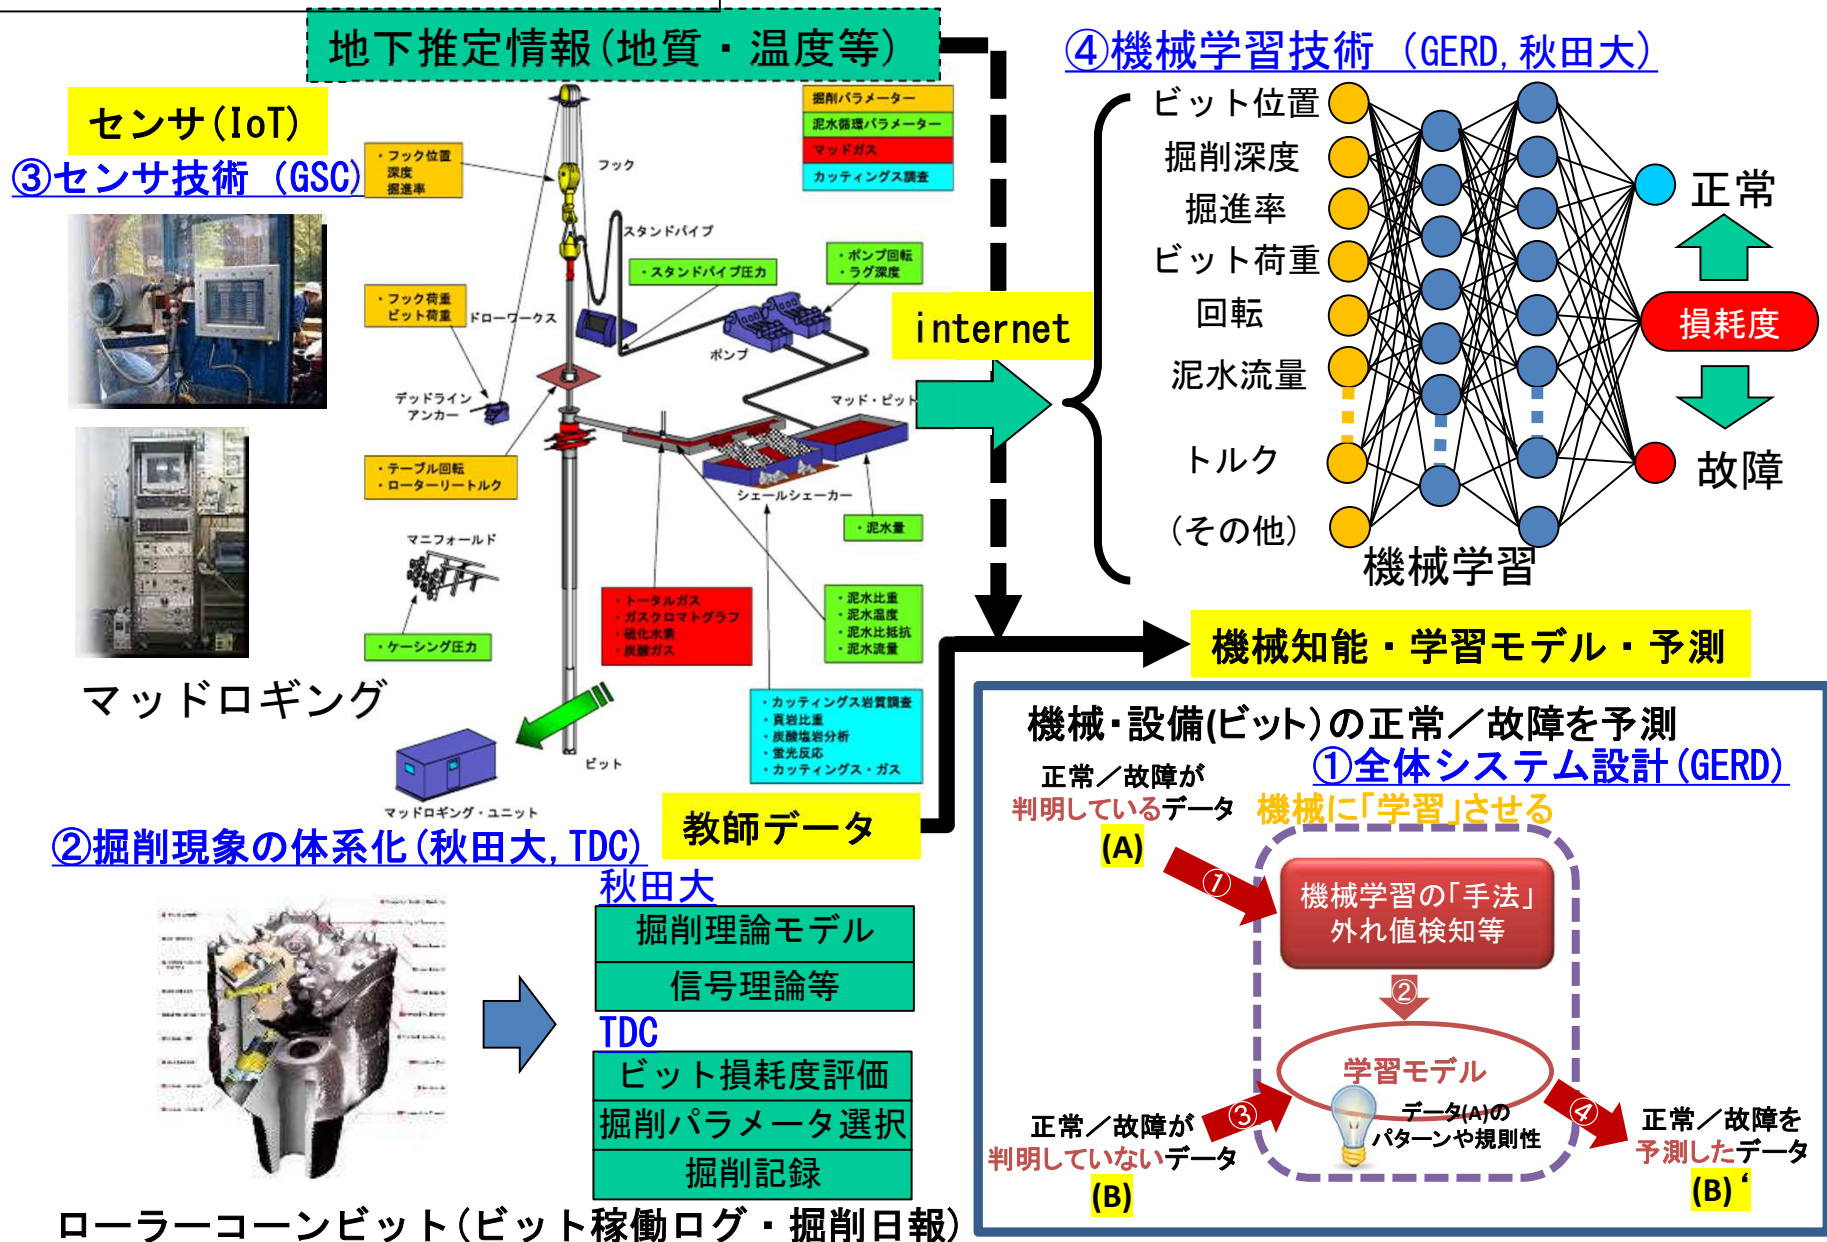
実施体制

AIによる超臨界地熱資源掘削技術



開発項目と実施分担

AIによる超臨界地熱資源掘削技術



成果例

「掘削現象の体系化」 (帝石削井工業(株))

スライド掘削時のビットベアリング摩耗判定

スライド掘削時は掘削編成を回転させないため、


ビット状況の情報取得・判定に掘削トルクは使えない。

→ ビットの損耗によりマッドモーター(DHM)に負荷が掛かるとポンプ圧力が変動するが、ポンプ圧力は循環量やビット荷重だけでなく地質状況や泥水性状等も影響するためポンプ圧力によるビット損耗の判定は難しい。

→ ビット損耗を判定するためのパラメータとして、ビットを掘削肌に付けてビット荷重を増加させ掘削を行う際の、**ビット荷重と循環圧力の変化(ΔP : 差圧の変化)に着目。**

→ 実際の掘削では、スライド掘削の中で掘削編成の Pick upと、掘削を繰り返すため、**スライド掘削毎に、ビット荷重と ΔP のデータを収集し、摩耗判定の可能性を検討。**

(ΔP = On bottom pressure – Off bottom pressure)



掘削モードの坑内模式図

ビットデータの追加収集と選定


当初入手したビットデータでは損傷ビットは少なく(2丁/34丁)、**判定結果の検証が困難。**

- 3地域5坑井より**ビットデータ(ビット数 43)**を追加入手。
- ビット記録や日報を元に、**ビットデータを選定した。**

| 地域 | 12-1/4" | 8-1/2" |
|----|---------|--------|
| 1 | 1 | 0 |
| 2 | 2 | 3 |
| 3 | 0 | 4 |

✓ 回収後にベアリング評価が「良好(E)」と判定されたビットのスライド掘削時データ


スライド掘削 3回目 4回目 7回目 10回目



※ スライド掘削の回数が増えても、ビット荷重に対する縦軸: 差圧(ΔP)のばらつきが少ない

✓ 回収後にベアリング評価が「不良(F)」と判定されたビットのスライド掘削時データ

スライド掘削 2回目 3回目 8回目 9回目




※ スライド掘削の繰り返により、縦軸: 差圧(ΔP)のばらつき幅が広がっている

スライド掘削における、差圧によるビットベアリング摩耗判定の有効性を示唆

✓ 追加データにおけるベアリング評価が「不良(F)」判定ビットについて確認

スライド掘削 2回目 6回目 7回目 8回目 11回目



※ 追加のビットデータにおいても同様の傾向を示した。(低トルク型DHMIは、より特徴的)

検証試験結果の検証と評価

- K-近傍法によるAI判定結果(18丁)について、**削井サイドから検証・評価を行った。**
- 本業務で実施した「**ビット使用評価法**」を元にビット使用継続を推測し、**AI判定と比較。**

| Bit | AI 判定 | 個数 |
|-----------|-------|----|
| F (12) | 異常 | 8 |
| | 中間 | 4 |
| | 正常 | 0 |
| E (6) | 異常 | 2 |
| | 中間 | 4 |
| | 正常 | 0 |

※ ベアリング損傷により長時間の掘削継続が期待できないという評価をしたものは、AI判定においても「異常」の判定が多い。

※ ベアリングが F 評価で「中間」と判定されたものは、AI判定側(判定基準・精度)によるものではなく、ベアリングを評価する際の「判定のばらつき」によることも考えられる。

※ 一方で、ベアリングが E 評価で「異常」と判定されたものは、ベアリング以外の評価が悪い(ダメージが大きい)。

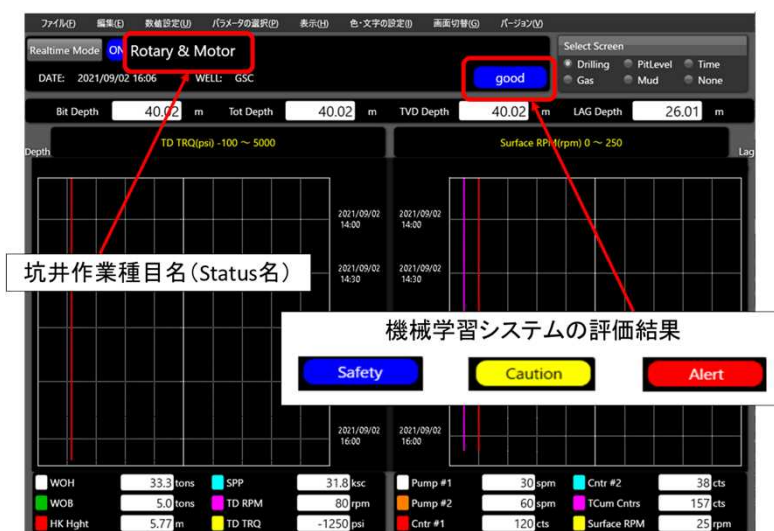
※ ビットのベアリングに焦点を当てて、ロータリーモード掘削、スライドモード掘削における判定手法を提案したが、AI 判定結果ではベアリング以外の要素の影響も示唆された。

成果例

AIによる超臨界地熱資源掘削技術

「センサ技術」(株)物理計測コンサルタント

- 機械学習システムの構築に必要な既存井のマッドロギングデータの提供
 - ①指定された既存井のデータをビット毎に抽出して提供(表ー1), ② 機械学習システムの解析を支援する掘削モード(ロータリーのための掘削、ロータリーとモータ併用掘削、スライド掘削)を含む作業種目情報を提供データに付加。(表ー2)
- 機械学習システムに情報提供可能なマッドロギングシステムの構築
 - ①マッドロギングのデータ収録、表示機能に作業種目情報(ステータス名、ステータス値)を追加した。
 - ②機械学習システムにデータ送信機能を追加して、クラウド(AWS)に送信可能とした。
- マッドロギングに機械学習システムの評価結果を取得、表示、警報する機能を追加した。



図ー1 作業種目名と機械学習システムの評価結果の表示例

表ー2 坑井作業種目とステータス

| 坑井作業種目名 | ステータス名 | ステータス値 |
|----------------|------------------------|--------|
| ロータリー掘削 | Rotary | 95 |
| ステアブルモーター掘削 | Slide | 90 |
| モーターとロータリー併用掘削 | Rotary & Motor | 85 |
| オンボトム循環 | Circulation On Bottom | 80 |
| オンボトム循環停止 | On Bottom | 70 |
| 浚い | Reaming | 60 |
| オフボトム循環 | Circulation Off Bottom | 50 |
| オフボトム循環停止 | Off Bottom | 40 |
| オンスリップ | On Slip | 30 |
| トリップ中のオンスリップ | On Slip-TP | 25 |
| トリップ&循環 | Circulation Trip | 20 |
| トリップ&循環停止 | Trip | 10 |

表ー1 坑井別マッドロギングデータの抽出・提供ビット丁数

| 年度 | ビット径 | 坑井名 | | | | | | | | | | 小計 | 合計 |
|-------|---------|-----|---|---|---|----|---|---|---|---|---|----|----|
| | | A | B | C | D | E | F | G | H | I | J | | |
| 2019年 | 8-1/2" | 5 | 7 | 7 | 7 | 11 | | | | | | 37 | 55 |
| 2020年 | 12-1/4" | | | | | | 1 | | 2 | | | 3 | |
| | 8-1/2" | | | | | | | 2 | 5 | 1 | 7 | 15 | |

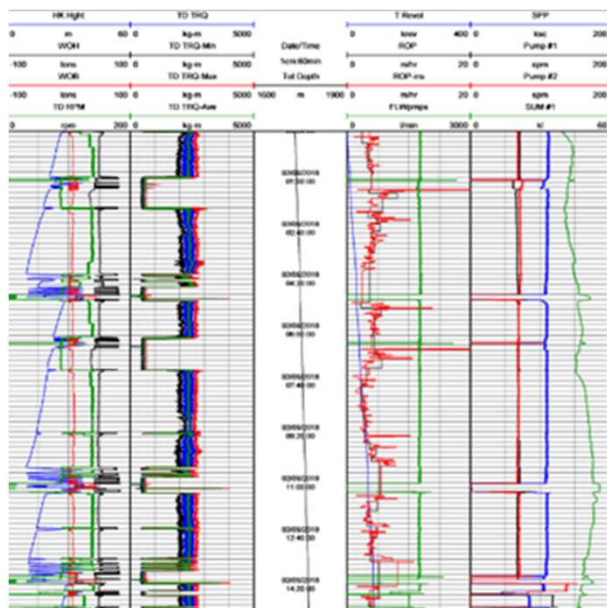
成果例

AIによる超臨界地熱資源掘削技術

「掘削現象の体系化（理論的アプローチ）」「機械学習技術」（秋田大学）

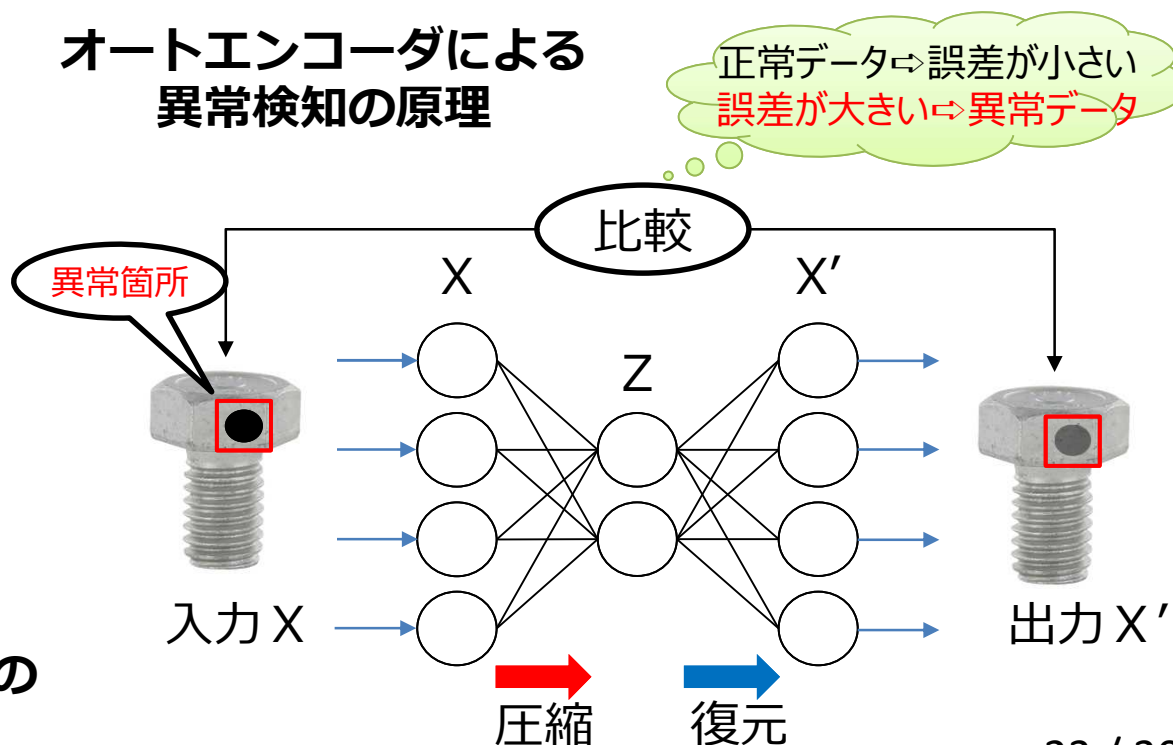
AI・機械学習によるビット異常検知手法の検討

- 泥水検層（マッドロギング）データのビット荷重、ビットトルク、掘進率、差圧、比掘削エネルギーなどの時系列データからAI・機械学習を用いてビットの異常を検知
- ニューラルネットワークのひとつであるオートエンコーダ（autoencoder）を採用
 - 入力と出力が同じになるように学習してネットワークを構築
 - 正常時の掘削データのみを用いて学習を行うと、異常を含むデータ进行处理した場合に出力が入力に一致しない、つまり異常であることを判定可能
 - 教師データとしての掘削異常データが無くても異常検知が可能



泥水検層による地熱井掘削中の
各種取得データ

オートエンコーダによる 異常検知の原理



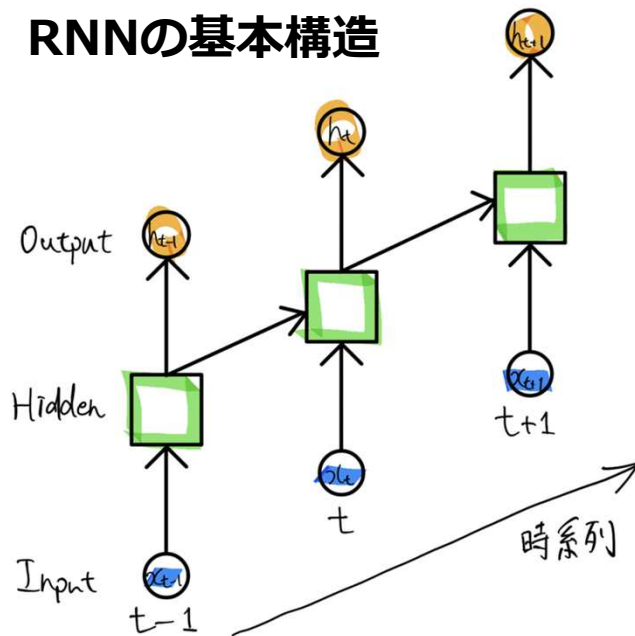
成果例

「掘削現象の体系化（理論的アプローチ）」「機械学習技術」（秋田大学）

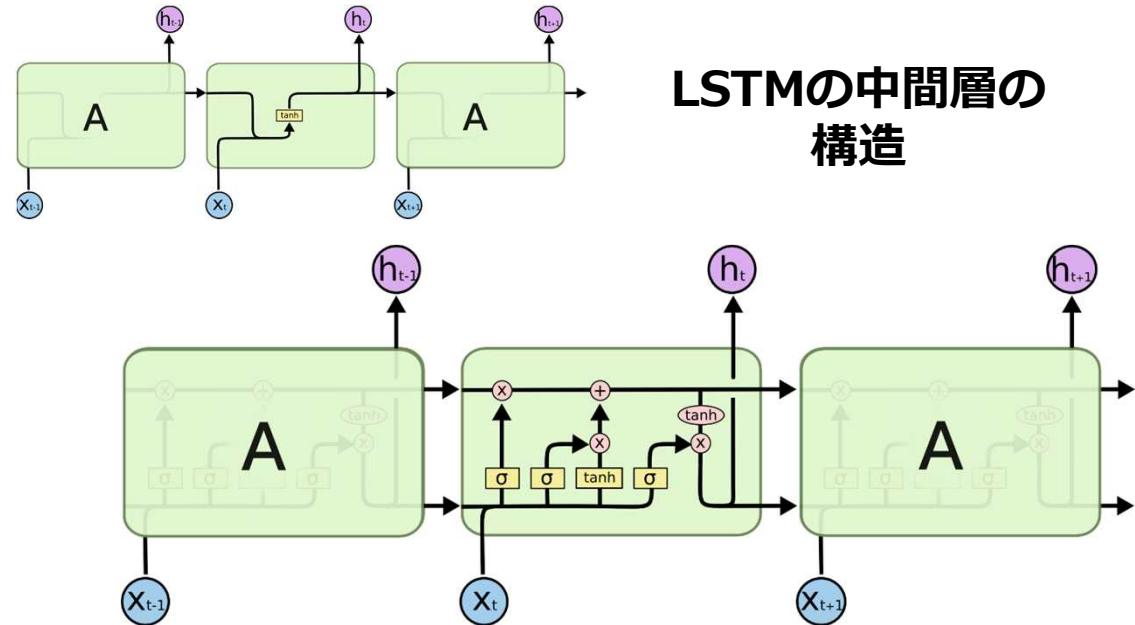
Python言語によるオートエンコーダの実装

- RNN（Recurrent Neural Network、再帰型ニューラルネットワーク）
 - 系列データのパターンを認識するよう設計されたニューラルネットワーク
- LSTM（Long Short-Term Memory、長・短期記憶）
 - RNNの中間層のユニットをLSTM Blockと呼ばれるメモリと3つのゲートを持つブロックに置き換えることで実現
 - 損失関数の勾配消失・発散問題を解決し、長期系列データの学習が可能
- Encoder-Decoder双方でLSTMを使用することで時系列データを復元

RNNの基本構造



LSTMの中間層の構造




成果例

AIによる超臨界地熱資源掘削技術


「掘削現象の体系化（理論的アプローチ）」「機械学習技術」（秋田大学） 実掘削データを用いたビット摩耗検知の解析例

- Python言語による異常検知プログラムのコーディング
 - マッドロギングデータから掘進時データのみを抽出する前処理
 - 時系列を扱うLSTMオートエンコーダの構築
 - 異常値の評価法の検討
- 国内地熱井掘削時のマッドロギング実データを用いてシステムの検証と解析結果を評価
 - オートエンコーダニューラルネットワークを用いた学習により、マッドロギングデータからビットのベアリング摩耗や歯先摩耗などの特定の現象を抽出可能

ビット摩耗（歯先摩耗量50%）



ベアリング損傷



Python版プロトタイプオートエンコーダによる解析例


成果例

AIによる超臨界地熱資源掘削技術

「全体システム設計」・「機械学習技術」（地熱技術開発(株)）

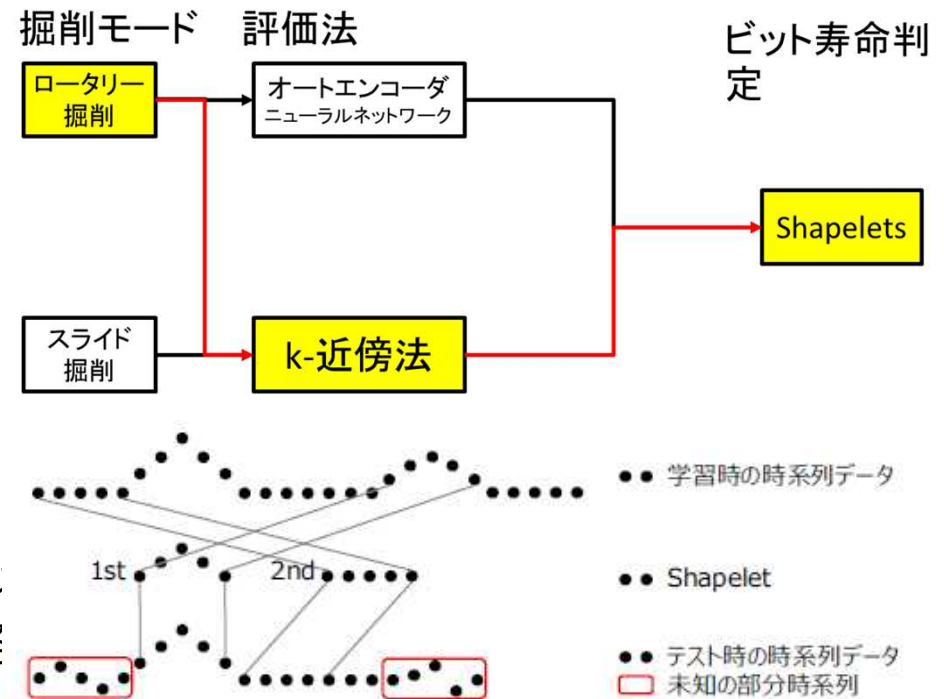
k近傍法:KNN(K Nearest Neighbor)による外れ値検知

ある点から最も近い k 個の点を考慮して外れ値検知を行う。対象の点から近傍の k 個の点を含むような円を描き、円の半径を ε とする。



例えば上図の場合では $k=5$ のときを考え、データ群から離れた異常点が描く円の半径 ε は正常データ群のものよりも大きくなっていることが判る。この性質に基づき、 ε を異常度として使用して外れ値検知を行う。具体的には、 ε がある閾値を超えた場合は異常、そうでない場合は正常といったようにスカラー値に落として外れ値を検出する。

ビット寿命判定法について (Shapeletsによる判定)



分類器を学習することで分類に有効な波形パターンである時系列 shapeletを発見する

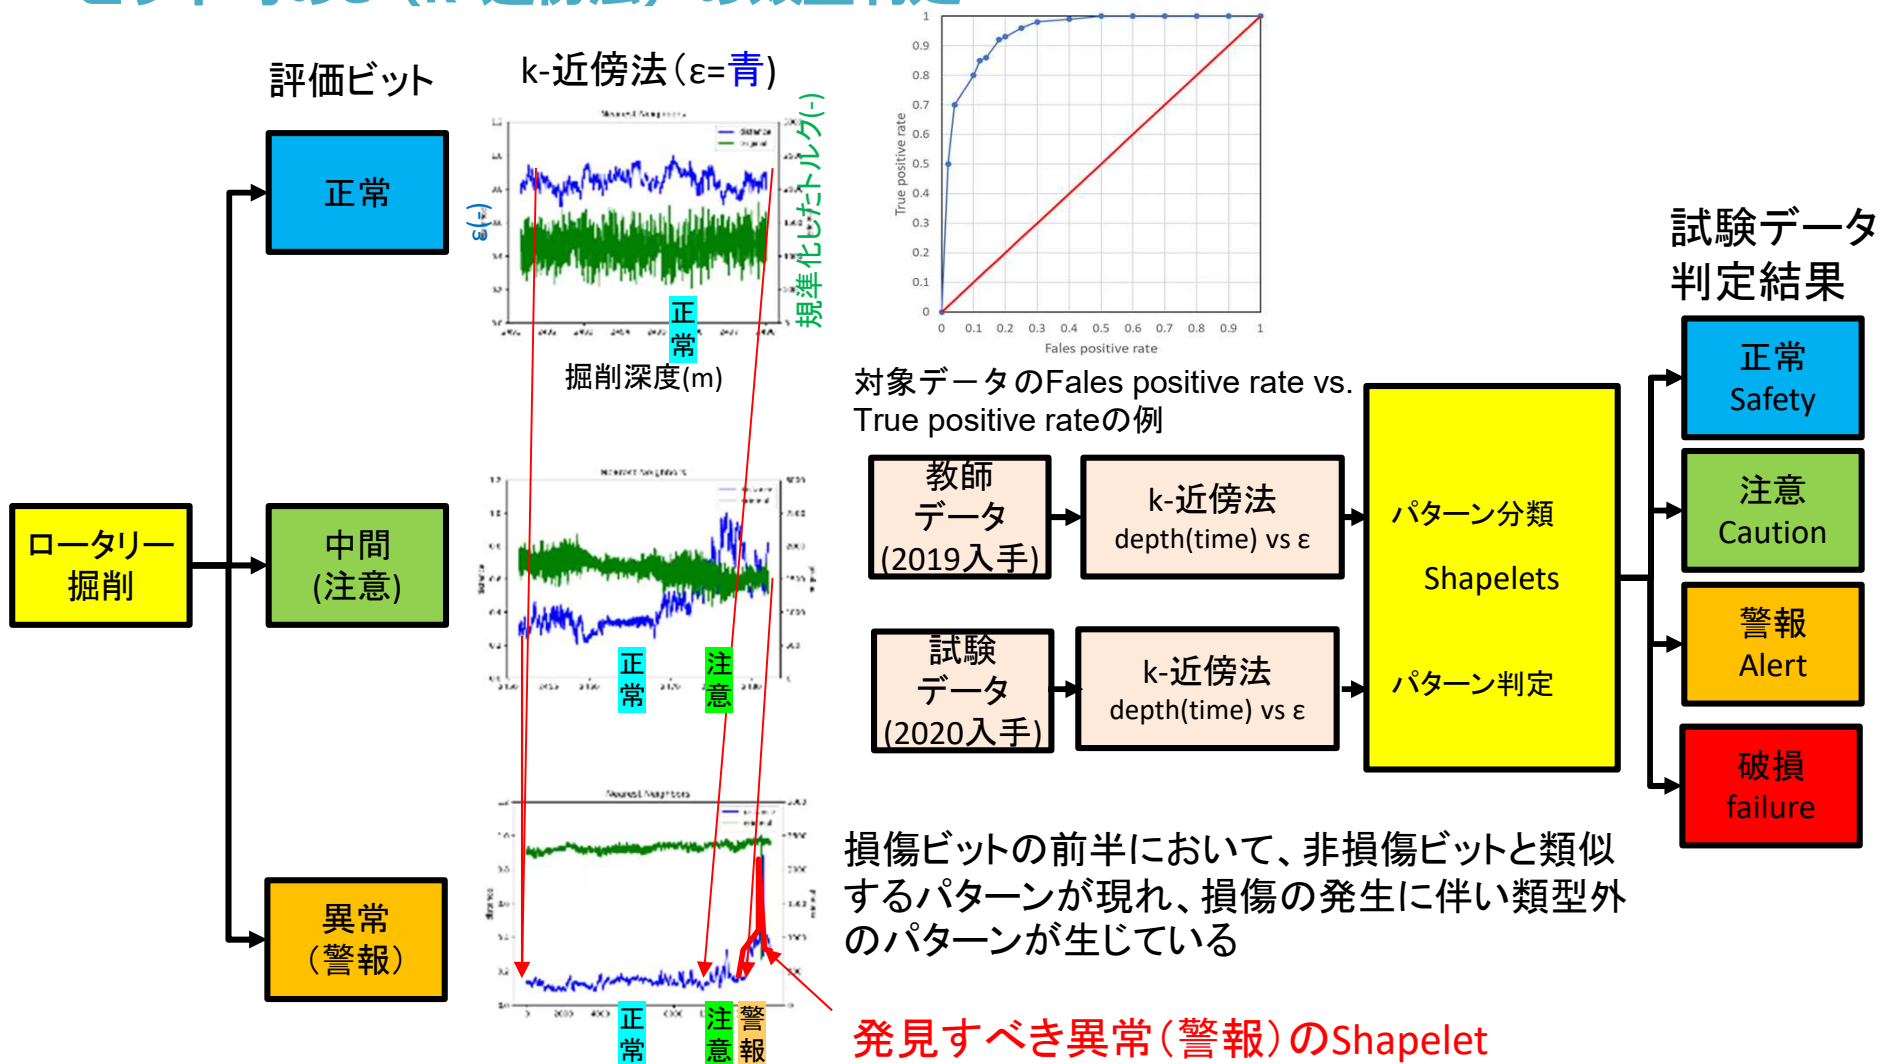
成果例

AIによる超臨界地熱資源掘削技術

「機械学習技術」(地熱技術開発(株))

Shapeletsによるビット寿命判定

ビット毎の ϵ (k-近傍法) の類型判定



成果例

AIによる超臨界地熱資源掘削技術

「機械学習技術」(地熱技術開発株)

2020年度入手データに対する機械学習判定結果

| # | 故障判定抽出順位 | 地域 | 坑井 | BIT No. | 機械学習判定結果 | | |
|----|----------|----|----|---------|----------|----|----|
| | | | | | 正常 | 注意 | 異常 |
| 1 | 9 | ② | A | 5 | | | ○ |
| 2 | | ② | B | 9 | | ○ | |
| 3 | | ② | B | 13 | | ○ | |
| 4 | 8 | ③ | A | 6 | | ○ | |
| 5 | 7 | ③ | A | 6a | | | ○ |
| 6 | | ③ | A | 9 | | ○ | |
| 7 | 3 | ③ | A | 10 | | | ○ |
| 8 | | ③ | A | 15 | | ○ | |
| 9 | 6 | ③ | A | 16 | | | ○ |
| 10 | 10 | ③ | A | 17 | | | ○ |
| 11 | 1 | ④ | B | 17 | | | ○ |
| 12 | | ④ | C | 14 | | ○ | |
| 13 | 2 | ④ | C | 15 | | | ○ |
| 14 | | ④ | C | 16 | | | ○ |
| 15 | 4 | ④ | C | 17 | | | ○ |
| 16 | | ④ | C | 18 | | ○ | |
| 17 | 5 | ④ | C | 19 | | | ○ |
| 18 | | ④ | C | 20 | | ○ | |

判定結果としての的中率
100%-11.1%=88.9%となり、高い精度でのビット寿命判定結果が得られた。

| | | |
|----------|------|-------|
| 異常判定の的中率 | 9/10 | 90.0% |
| 判定ミスの発生率 | 2/18 | 11.1% |

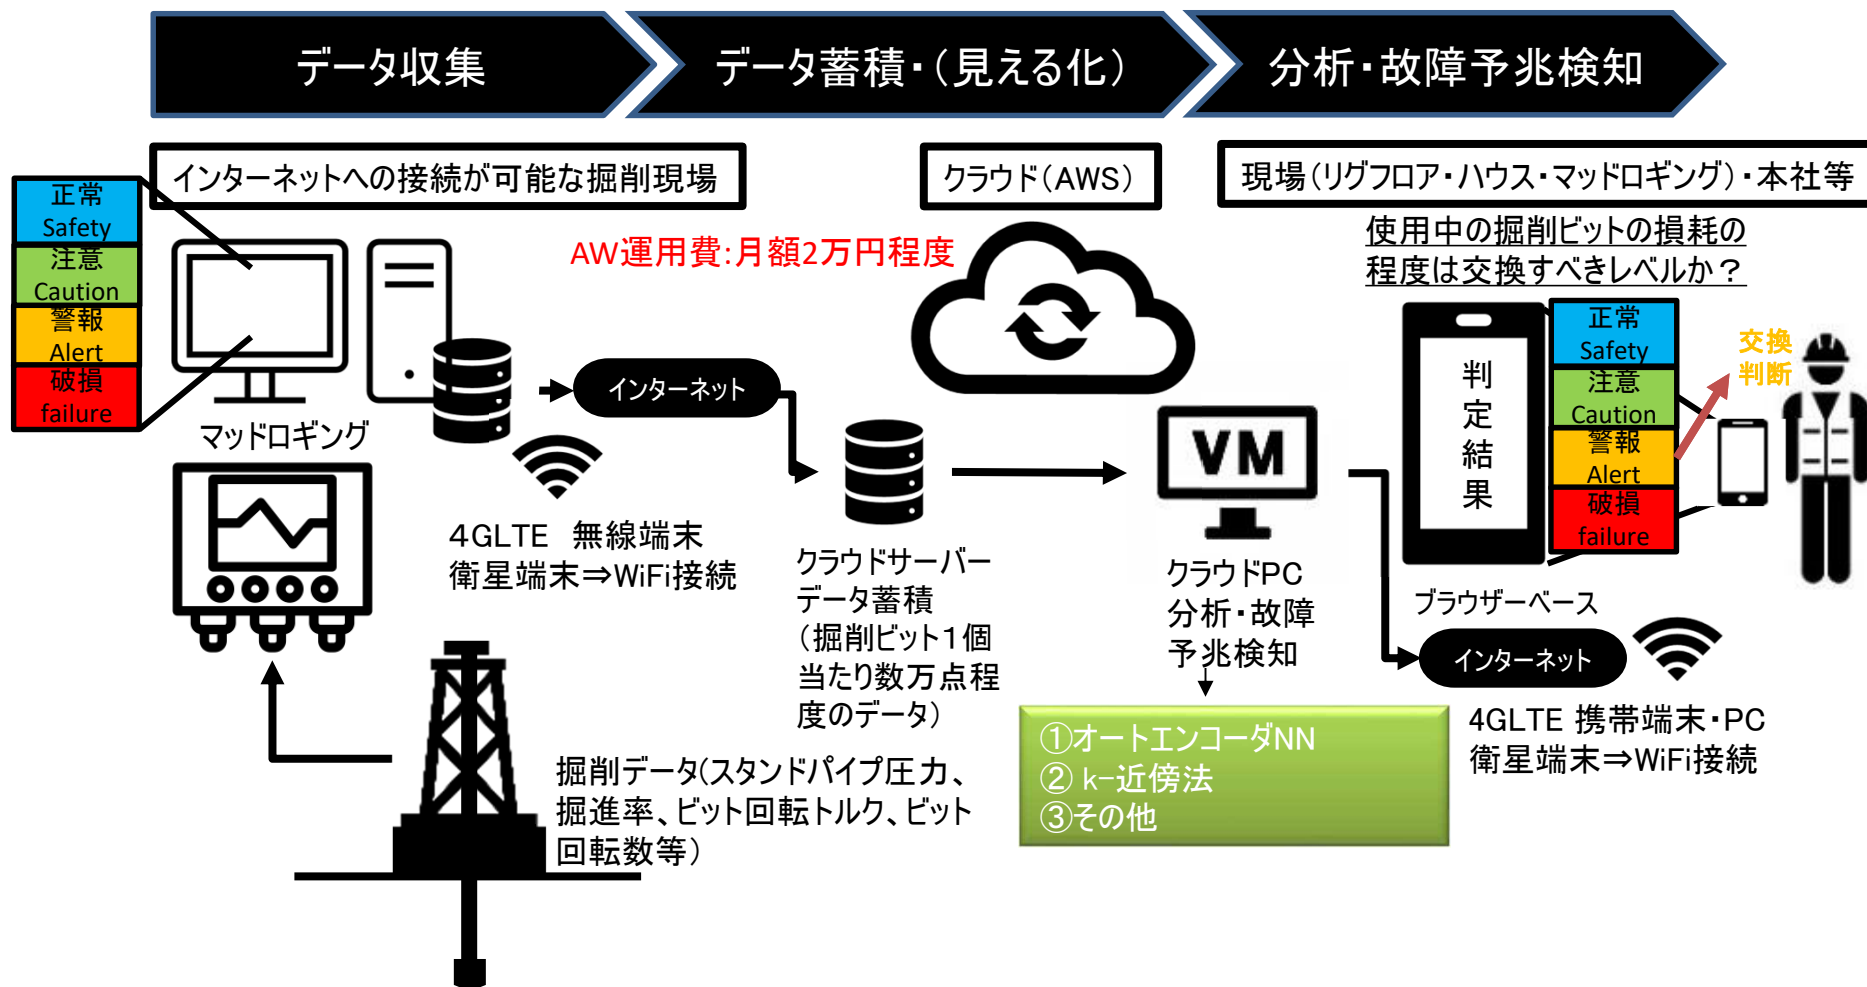
成果例

AIによる超臨界地熱資源掘削技術

「全体システム設計」・「機械学習技術」 (地熱技術開発(株))

システムの実装について

クラウド型システム(基本)の例 ※通信環境が悪い場合は、独立型も可能



※問題点: 地熱地帯の通信環境が乏しい(独立型で対応)

※利点: 携帯端末へのソフトのインストールのみで専門家の派遣不要

目標達成状況

AIによる超臨界地熱資源掘削技術

| 開発項目 GE:GERD, T:TDC, GS:GSC, A:秋田大 | | 目 標 | 成 果 (達成度) |
|---------------------------------------|---|---|--|
| ① 設計システム | 1) 設計(GE) 2) システム実装と検証試験(GE) | ビットの損耗度の予測により、現実の計測数値と誤差20%程度の精度を達成する | 全体システムの概念設計・基本設計の実施、実装したシステム(クラウド上の仮想マシン)による検証を行った。損傷ビットと正常ビットの評価で88.9%の正答率を得た。(○) |
| ② 掘削現象の体系化 | 1) 過去の掘削記録の収集(T) 2) 掘削ビットの損耗に関わる評価データ抽出・現象の体系化(T) 3) 機械学習データ整備(T) 4) 理論的体系化(A) | ビット損耗度に関連する有効な掘削パラメータの抽出 機械学習手法の開発ならびに技術検証に必要なデータの整備 | ビットの損耗に関わる評価値を整理した。 掘削パラメータのうち、ビットの損耗に影響するパラメータを選定して、機械学習に提供した。 34例(+追加データ18例)のデータを収集・整理して、機械学習側に供与した。 掘削挙動モデルの整理と有効な機械学習法の整理を行った。(○) |
| ③ センサ技術 | 1) マッドロギング計測システム検討(GS) 2) 基本仕様整備(GS) | 機械学習に情報供与可能なマッドロギングシステムの構築 | ビットの損耗度評価に必要な計測システムの仕様を作成した。 機械学習側で必要とする掘削情報をマッドロギングシステムに追加した。(○) |
| ④ 機械学習 | 1) 有効な機械学習手法の選定(A,GE) 2) 選定した機械学習手法によるビットの損耗度評価(A,GE) | 有効な機械学習法の確立 | 有効な機械学習法として、オートエンコーダNN、k-近傍法を選定して、Shapeletsに基づき実際のマッドロギングデータからビット損耗度(故障)の抽出に成功した。(○) |
| 今後の課題と実用化の見通し | | 実フィールドでのデータ蓄積と評価を行い、オートエンコーダNNとk-近傍法による評価を総合して予測精度の向上を図る。クラウドサービスへの実装(セキュリティーの検証)・通信環境の悪い地点でのサービスの検討後に実装する予定。 | |