

灰障害予測に対する機械学習の適用

宮下 和大^{*1} 田内 希^{*1} 茂田 潤一^{*2}
Miyashita Kazuhiro Tauchi Nozomi Shigeta Jun-ichi

当社では石炭灰の膠着度(かたさ)を指標として石炭焚きボイラにおける灰障害の起こりやすさを評価してきた。膠着度試験は石炭試料を粉碎、灰化、再焼結した後に焼結体のかたさを測定する手法である。膠着度試験は、ラボにて灰障害を予測できる有用な手法であるが、その反面、灰化などの処理に時間が掛かる。そこで、灰障害の起きやすさを事前に評価できれば、時間が短縮できる。本稿では、石炭灰の温度・化学組成に基づく機械学習を適用し、機械学習の予測結果と膠着度の相関について検討した。その結果、正解率 83%で膠着度を予測できることが確認され、灰障害のスクリーニング手法として機械学習は有効であることを確認した。

キーワード：灰障害、膠着度、機械学習、石炭

1. はじめに

石炭焚き火力発電ボイラでは、石炭の燃焼によって生じた灰が伝熱管に付着、成長し、伝熱性の低下や閉塞を引き起こす灰障害が発生する。灰障害の起こりやすさは石炭の種類により差があるため、当社では灰障害の起こりやすさを評価する

手法として膠着度試験を提供し、定量的に評価してきた⁽¹⁾。図1に、膠着度測定の概略を示す。膠着度試験ではまず電気炉で石炭を完全に燃焼させ、石炭灰を調製する。次に、調製した石炭灰を専用の磁性皿に詰め、管状炉内にて実機ボイラの燃焼温度近傍で加熱する。その結果磁性皿内に灰の焼結体が生成されるので、そのかたさから膠着

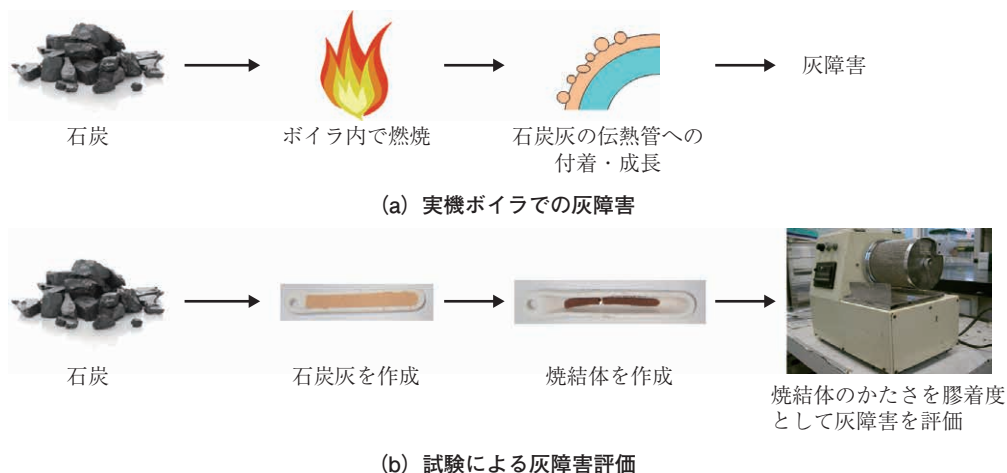


図1 膠着度測定の概略

*1：研究開発センター 研究開発グループ

*2：元フェロー 博士(学術) 環境計量士(濃度関係)

度を求める。膠着度と灰障害の程度の関係⁽¹⁾を表1に示す。焼結体がかたく壊れにくいと膠着度は高くなり、灰障害が生じやすいことを意味する。

膠着度は、ラボにて灰障害を予測できる有用な手法であるが、測定には準備を含め時間が掛かる。仮に、石炭灰の化学組成情報をもとに灰障害の起こりやすさを評価できれば、成分分析のみで灰障害の危険性を予測でき、条件を的確に絞り込んだ膠着度試験が可能となる。そこで、本稿では、近年実用化が進んでいる機械学習を用いて、石炭灰の化学組成情報から膠着度の予測を試みた。

2. 膠着度、石炭灰組成データについて

膠着度に影響を与える因子には、温度および灰組成が知られている。高温または、灰の融点を降下させるアルカリ金属 (Na、K) 酸化物が多い条件で⁽²⁾、灰の溶解性が高くなり、その結果膠着度が高くなる。そこで、膠着度を予測するパラメータとして、温度と灰組成を選定した。

まず、組成の異なる 77 種類の石炭灰に対し、1000、1100、1200℃での膠着度を測定した。

膠着度試験条件は以下の通りである。

- ①温度：1000、1100、1200℃
- ②圧力：大気圧
- ③雰囲気：空気

また、それぞれの石炭灰の組成は蛍光 X 線法による分析結果から灰組成を求めた。分析対象は以下の通りである。

分析対象：SiO₂、Al₂O₃、TiO₂、Fe₂O₃、CaO、MgO、Na₂O、K₂O、SO₃、P₂O₅、MnO

一方、膠着度と灰障害の程度は表2のような関係があり、実機付着灰調査から、膠着度が0.8以上のときに灰障害(スラッキング・ファウリング)を起こす⁽¹⁾ことが確認されている。そこで機械学習では、膠着度0.8をしきい値として、0.8以上をBad判定、0.8未満をGood判定として用いた。

3. 機械学習による評価

機械学習とは、答えのわかっているデータを学習データとして与えて推定モデルを作成し、この推定モデルを用いて答えのわからないデータから答えを予測するというものである。今回は下記の図2に示す流れでデータを評価した。

まず、組成と膠着度のわかっている 77 灰種 ×

表1 膠着度と灰障害の程度の関係⁽¹⁾

実機灰の付着状態	灰障害の程度	膠着度
パウダー状で付着	なし(◎)	< 0.2
手では簡単に崩すことができる	小(○)	0.2 ~ 0.4
手では簡単に崩すことができない	中(△)	0.4 ~ 0.8
崩すことができない (溶解してガラス状態)	大(×)	> 0.8

表2 膠着度の判定基準

実機灰の付着状態	灰障害の程度	膠着度
パウダー状で付着	なし(◎)	< 0.2
手では簡単に崩すことができる	小(○)	0.2 ~ 0.4
手では簡単に崩すことができない	中(△)	0.4 ~ 0.8
崩すことができない (溶解してガラス状態)	大(×)	> 0.8

膠着度：0.8 未満
判定：Good

膠着度：0.8 以上
判定：Bad

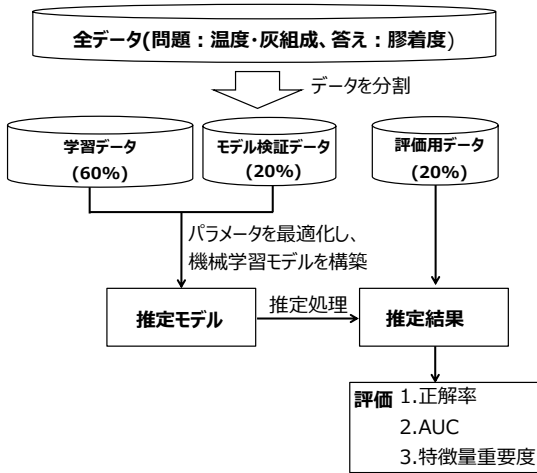


図2 機械学習評価フロー

3 温度を、学習データ (60%)、モデル検証データ (20%)、評価データ (20%) に分ける。次に、学習用データから機械学習モデルを構築し、モデル検証データの正解率が最も高くなるようにパラメータを最適化し、推定モデルを構築する。このとき、使用する検証データを固定することでモデルの性能に偏りが出ることを避けるために、学習データとモデル検証データの組み合わせを5通りに変えながら検証し(交差検証)、平均正解率で判断した。そして、構築した推定モデルを用いて、評価用データから結果を推定し、正解との比較をもとに推定モデルを評価した。

機械学習モデルとしては、①決定木、② RandomForest、③ LightGBM(Light Gradient Boosting Machine)の三種類を選定し、それぞれに最適な推定モデルを構築した。

ここで①の決定木とは、分類問題を解く手法の一つであり、学習データを条件により分類してゆき、最後に結論を得る方法である。その概念図を図3に示す。

②の RandomForest とは、決定木を複数作成してそれぞれで判定し、その判定結果で多数決をとり、その結果を最終的な判断とする手法である(図4)。①の決定木に比べて、過学習、すなわち特定データに対してだけ正解率が高く、汎用データに対して正解率が低い状態になりにくいという特徴がある。

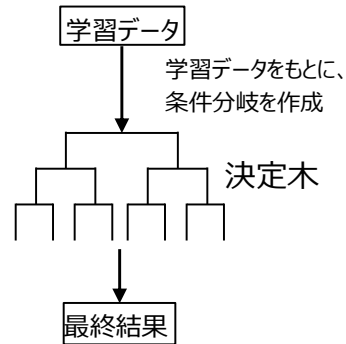


図3 決定木の概念図

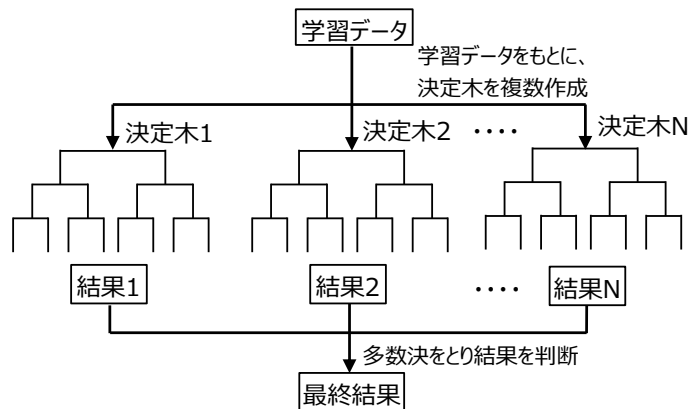


図4 RandomForest の概念図

③の LightGBM は、1つ目の決定木の結果をもとに誤差が小さくなるよう次の決定木を作成し、これを繰り返すことで最終的に結果の誤差を小さくしていく。そして、判定結果で多数決をとり、その結果を最終的な判断とする手法である (図 5)。

機械学習のモデルの評価としては、「正解率」、 「AUC (Area Under the ROC Curve)」、機械学習結果の妥当性の評価として「特徴量重要度」を選定し、これらを用いて評価した。

正解率とは、評価データのうち予測結果が正解だった数を全データ評価データ数で割った値と定義し、機械学習モデルによりどれだけ正確に予測ができていたかを意味する。

正解率 (%)

$$= (\text{予測の正解数}) / (\text{全評価データ数}) \times 100 \quad (1)$$

AUC とは、予測モデルの性能を評価する値の一つであり、ROC (Receiver Operating Characteristic)

曲線の下面積を意味する。ROC 曲線は縦軸に TPR (再現率)、横軸に FPR (誤判定率) をとったグラフである。まずは TPR と FPR について説明する。

表 3 に真値と機械学習で予測した値の関係を示す。表 3 は真値と予測値の関係ごとに名称が付けられたもので、例えば、真値が陽性 (Positive) で、予測の結果が陽性 (Positive) のとき、その関係は真陽性 (TP) という。

TPR (True Positive Rate) は、真値が陽性で、予測では陽性と正しく判定した割合 (再現率) を意味し、以下の式 (2) で表される。

$$\text{TPR} = \text{TP} / (\text{TP} + \text{FN}) \quad (2)$$

FPR (False Positive Rate) は、真値は陰性 (Negative) だが、予測では陽性と誤って予測した割合 (誤判定率) を意味し、以下の式 (3) で表される。

$$\text{FPR} = \text{FP} / (\text{FP} + \text{TN}) \quad (3)$$

式 (2)、式 (3) の関係から、TPR (再現率) が高く、

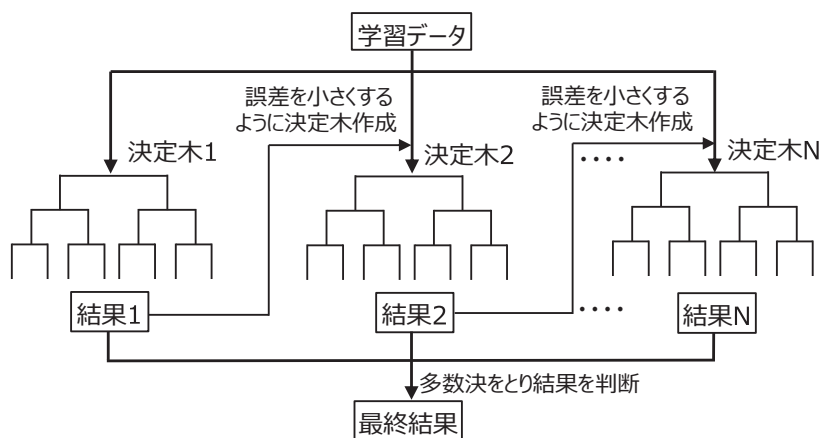


図 5 LightGBM の概念図

表 3 真値と予測値の関係

		予測値	
		陽性 (Positive)	陰性 (Negative)
真値	陽性 (Positive)	真陽性 (TP : True Positive)	偽陰性 (FN : False Negative)
	陰性 (Negative)	偽陽性 (FP : False Positive)	真陰性 (TN : True Negative)

FPR (誤判定率) が低い予測モデルが、陽性を陽性と正しく判定し、陰性を誤って陽性と判定する割合が少ないことを意味するので、モデルとしての性能が高いことを表す。また、機械学習モデルにおいて、TPR と FPR の関係をグラフ化したものを ROC 曲線という。図 6 に ROC 曲線と AUC の関係を示す。

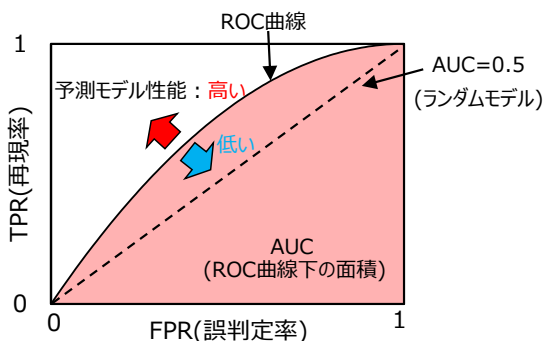


図 6 ROC 曲線と AUC の関係

予測モデルの性能が高いほど、ROC 曲線が左上に寄っていき、ROC 曲線の下面積である AUC は大きくなり、値が 1 に近づく。対して、予測モデルの性能が低いほど、ROC 曲線が右下に寄っていき、AUC は小さくなる。一般的に、AUC の値が 0.8 以上で良いモデルと評価される。また、AUC = 0.5 のときそのモデルは完全にランダムに選択した場合と同じ性能を意味し、予測の性能が低いことを意味する。

特徴量重要度 (Feature Importance) とはそれぞれの特徴量の結果への寄与度を判定する手法であり、ここでは試験温度や灰の成分が特徴量となる。値が大きいくほど重要な特徴量であり、判定するための因子としての寄与率が高いことを示している⁽³⁾。特徴量重要度を用いて、機械学習モデルの判断に対する妥当性を評価した。


4. 結果

4.1 機械学習と膠着度の比較


表 4 に①決定木、② RandomForest ③ LightGBM それぞれの機械学習手法で判定した場合の「正解率」と「AUC」の結果を、図 7 に「特徴量重要度」の結果を、

表 4 機械学習手法ごとの正解率と AUC


	決定木	RandomForest	LightGBM
正解率	81.0%	83.3%	83.3%
AUC	0.86	0.90	0.94



(a) 決定木



(b) RandomForest



(c) LightGBM

図 7 決定木、RandomForest、LightGBM の特徴量重要度

果を示す。表4から、機械学習の結果を比較すると、LightGBMが正解率とAUCの値がともに大きいことから、LightGBMが最も優れていることがわかる。またLightGBMは結果の値としても、正解率83.3%、AUC 0.94と高く、検討に値すると考えられる。

図7から、いずれのモデルを用いても温度が最も膠着度に影響を与えており、次にSO₃やK₂Oなどが判定に大きな影響を与えるという結果となっている。温度は灰の溶融を決定する要因であり、溶融することで膠着度が増すことが知られているため、温度が膠着度に大きな影響を与えるという結果は現象と一致している。次に、SO₃とK₂Oは高温環境下でアルカリ硫酸塩(K₂SO₄)やピロ硫酸塩(K₂S₂O₇)などの低融点の溶融塩物質を形成し⁽⁴⁾、その結果灰の溶融性が増加し、膠着度にも影響を与える。以上のように機械学習の判定は実際の現象の傾向に合致する。

4.2 混焼条件への灰障害予測手法の適用

4.1節にて、機械学習のうちLightGBMが最も精度良く膠着度を予測できることがわかった。未知のデータに対して、精度を検証するために、LightGBMによる機械学習の適用を確認した。

対象は、水分や不純物の多い低品位炭である亜瀝青炭と、不純物が少なく燃焼効率の良い高品位炭である瀝青炭、およびそれらの混合物を用いた。一般的に、低品位炭(亜瀝青炭)を多く混ぜると膠着度が高くなる。

ここでは、低品位炭と高品位炭の比率を変えた6試料に対し、3温度で膠着度を測定するとともに、それぞれの成分をLightGBMのモデルにかけてGood/Badを判定した。

混焼時の膠着度実測データと誤判定した箇所を表5に示す。

表5 混焼条件における膠着度と機械学習予測結果

No.	低品位炭：高品位炭	温度(℃)	膠着度(実測)	機械学習予測	正誤
1	10：0	1000	0.4	Good	○
2	10：0	1100	0.6	Bad	×
3	10：0	1200	0.9	Bad	○
4	7：3	1000	0	Good	○
5	7：3	1100	0.3	Good	○
6	7：3	1200	0.9	Bad	○
7	6：4	1000	0	Good	○
8	6：4	1100	0.2	Good	○
9	6：4	1200	0.9	Bad	○
10	5：5	1000	0	Good	○
11	5：5	1100	0.2	Good	○
12	5：5	1200	0.9	Bad	○
13	3：7	1000	0	Good	○
14	3：7	1100	0.1	Good	○
15	3：7	1200	0.9	Bad	○
16	0：10	1000	0	Good	○
17	0：10	1100	0.2	Good	○
18	0：10	1200	1	Bad	○

以上のように混焼比、低品位炭：高品位炭＝10：0、すなわち低品位炭のみの試料の1100℃の判定が実際はGoodのところをBadと判定したが、それ以外は正しい判定が得られた。すなわち全18データに対しての正解率は94%であった。混炭焚きにおいて本機械学習モデルを用いれば、高い精度で膠着度をもとにした灰障害発生予測が可能であると確認された。

5. まとめ

石炭灰において膠着度が0.8以上では灰障害を起こす懸念があるという基準をもとに、機械学習を用いた予測により、灰障害を起こす可能性の有無を正解率83%で判定できることを確認した。これにより、未知の燃料における灰障害発生スクリーニングへの利用が期待される。また、作成した機械学習アルゴリズムにて、混炭条件（未知データ）において適用した際にも、同等の精度が得られた。

今後は、利用が拡大しているバイオマス専焼ボイラへの適用の検討を進めていく。

参考文献

- (1) 知恵賢二郎、茂田潤一：灰汚れ評価「灰の膠着度」の垂漉青炭への適用について、IIC REVIEW、No.61、2019/04、pp.8-12
- (2) 内村大道、宮下和大：灰障害予測に対するシミュレーションの適用、IIC REVIEW、No.68、2022/10、pp.13-18
- (3) 湧田、山下、吉田他：インフラ維持管理業務での機械学習活用に向けたモデリング試行と結果の解釈に関する一考察、AI・データサイエンス論文集、2巻J2号、2021年、pp.437-446
- (4) 茂田潤一、梶ヶ谷一郎：燃焼灰の高温腐食試験法と腐食性評価の紹介、IIC REVIEW、No.34、2005/10、pp.32-38



研究開発センター
研究開発グループ
宮下 和大
TEL. 045-791-3522
FAX. 045-791-3547



研究開発センター
研究開発グループ
田内 希
TEL. 045-791-3522
FAX. 045-791-3547



元フェロー
博士(学術)
環境計量士(濃度関係)
茂田 潤一
TEL. 045-791-3516
FAX. 045-791-3542