

INTPIX4NAを用いたX線残留応力測定と 機械学習による転がり疲労の定量評価 II

滋賀大学

データサイエンス・AIイノベーション研究推進センター

三井真吾

(株)不二越 乾典規
金沢大学 佐々木敏彦



滋賀大学

- スラスト荷重試験
- X線残留応力・残留オーステナイト測定
- ミーゼス応力・せん断応力 τ_{yz} ・残留オーステナイトの時間変化
- 回帰分析
 - 線形回帰
 - 重回帰分析
 - 非線形回帰
 - ランダムフォレスト回帰分析
 - 多層パーセプトロン回帰分析
- まとめ

目的

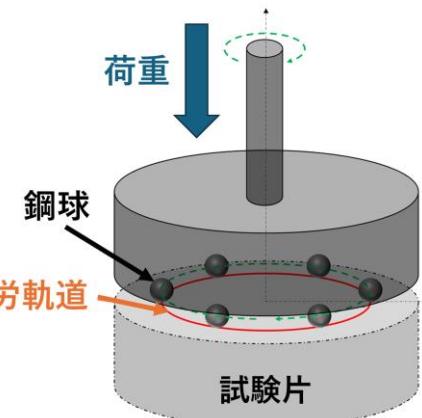
- 軸受やレールの損傷状態の定量的評価法を開発する。
- 転がり疲労の定量的な評価のために、スラスト荷重試験を行い、X線を用いた三軸応力・残留オーステナイト測定を行った。
- 測定データの**統計的解析・機械学習**により、鋼球通過回数の回帰分析を行った。

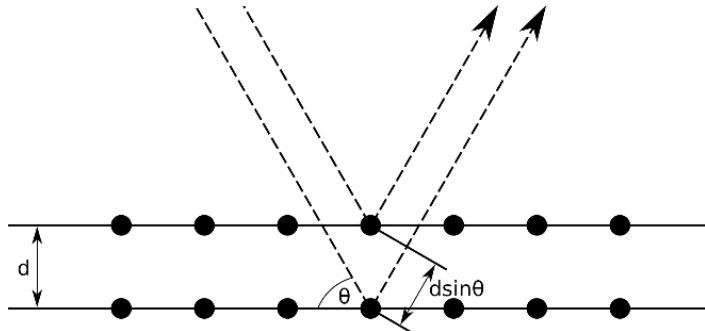
試験条件（詳細は乾さんと同様）

- SUJ2試験片
- 鋼球接触位置：半径19.25mm
- 鋼球通過回数： 10^8 回

測定条件(INTPIX4NA搭載X線残留応力測定装置)

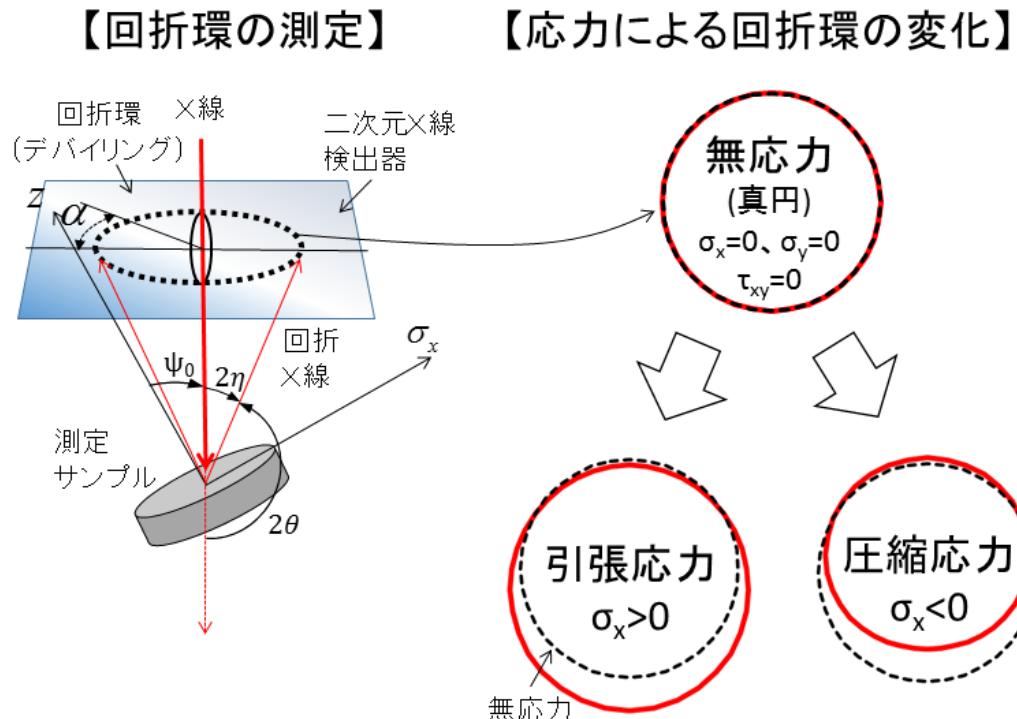
- 三軸応力、残留オーステナイト
- 測定した通過回数：0～ 10^8 回で16点
- 半径方向：16.25-22.25mmを0.5mm間隔で13点
- 円周方向：6度間隔で120点を60度分平均して6点





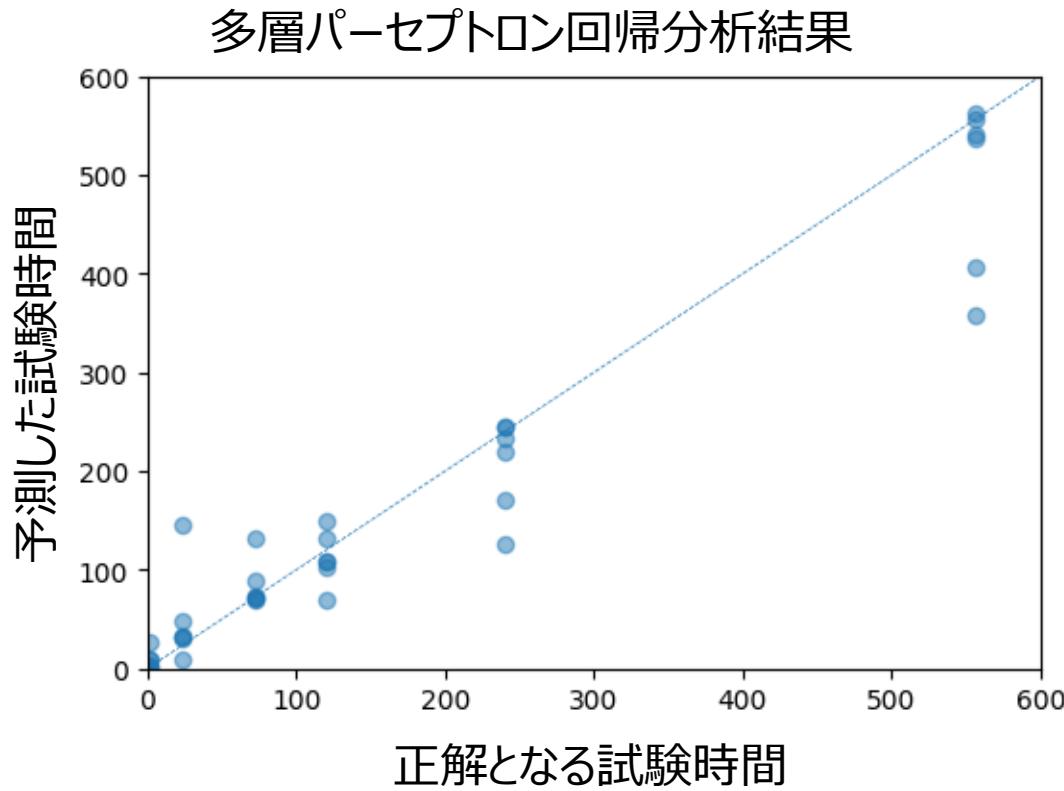
ブラッグの法則: $2d \sin \theta = n\lambda$

$$\frac{d - d_0}{d} \equiv \varepsilon = (\theta_0 - \theta) \cot \theta_0$$

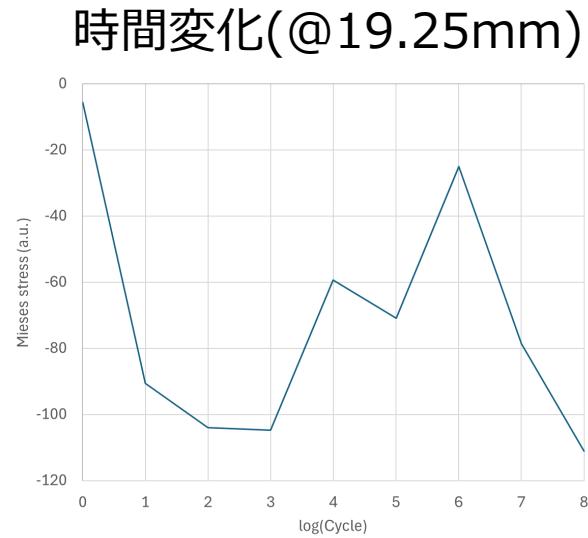
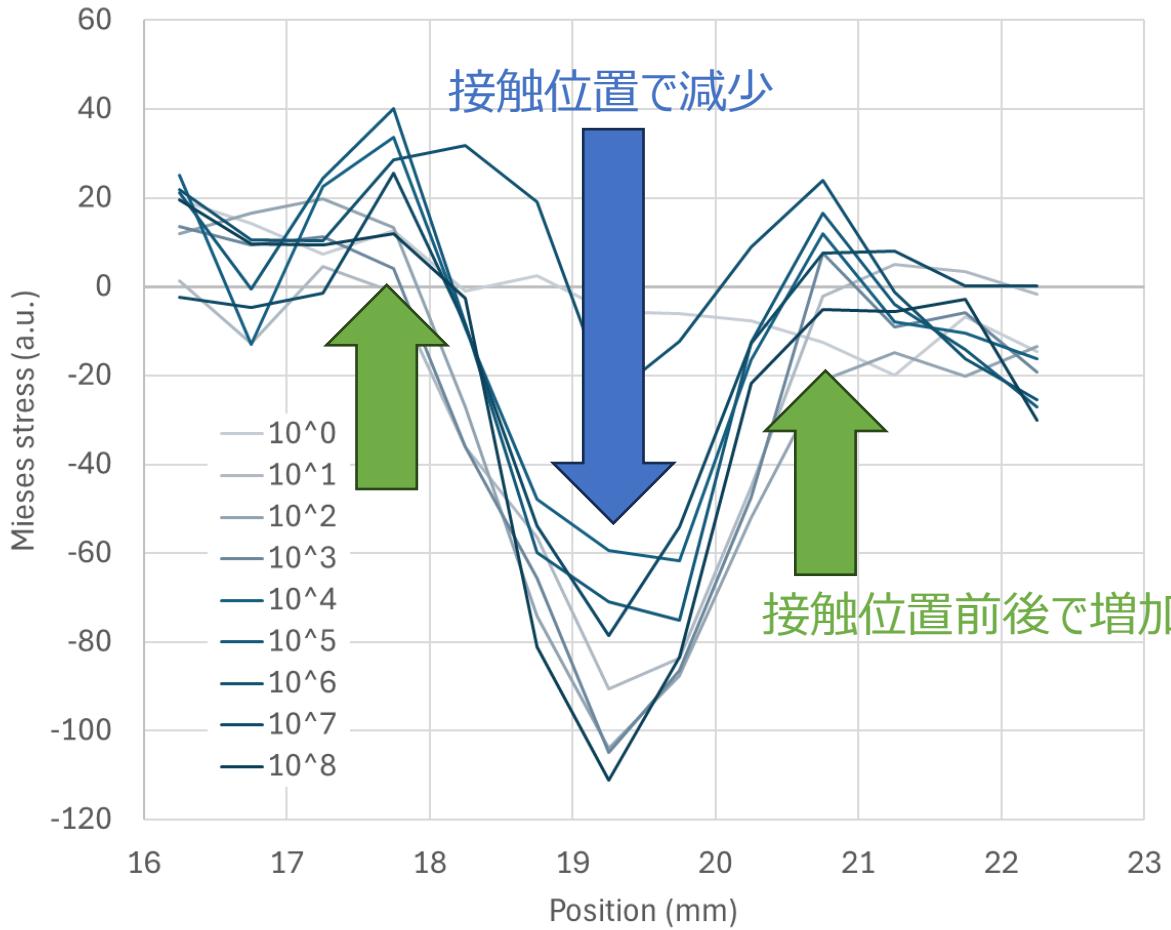


- 金属表面にX線を入射すると、ブラッグの法則により回折環が形成される。
- 残留応力によるひずみが回折環の変化として観測される。
- **回折環のゆがみ**：残留応力、回折環半価幅：転位密度(硬さ)、
2重の回折環の強度比：残留オーステナイト

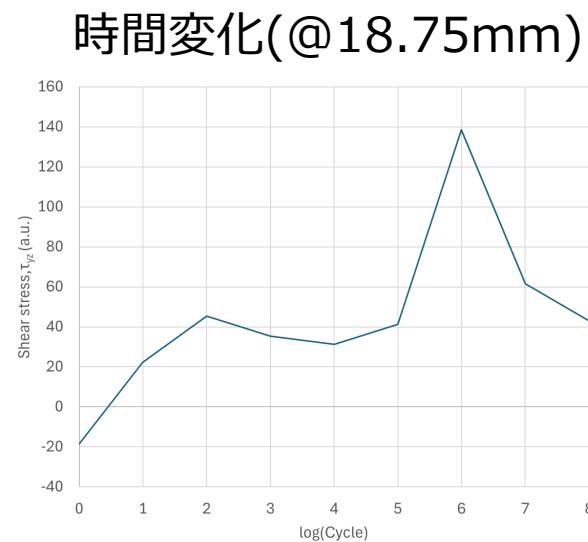
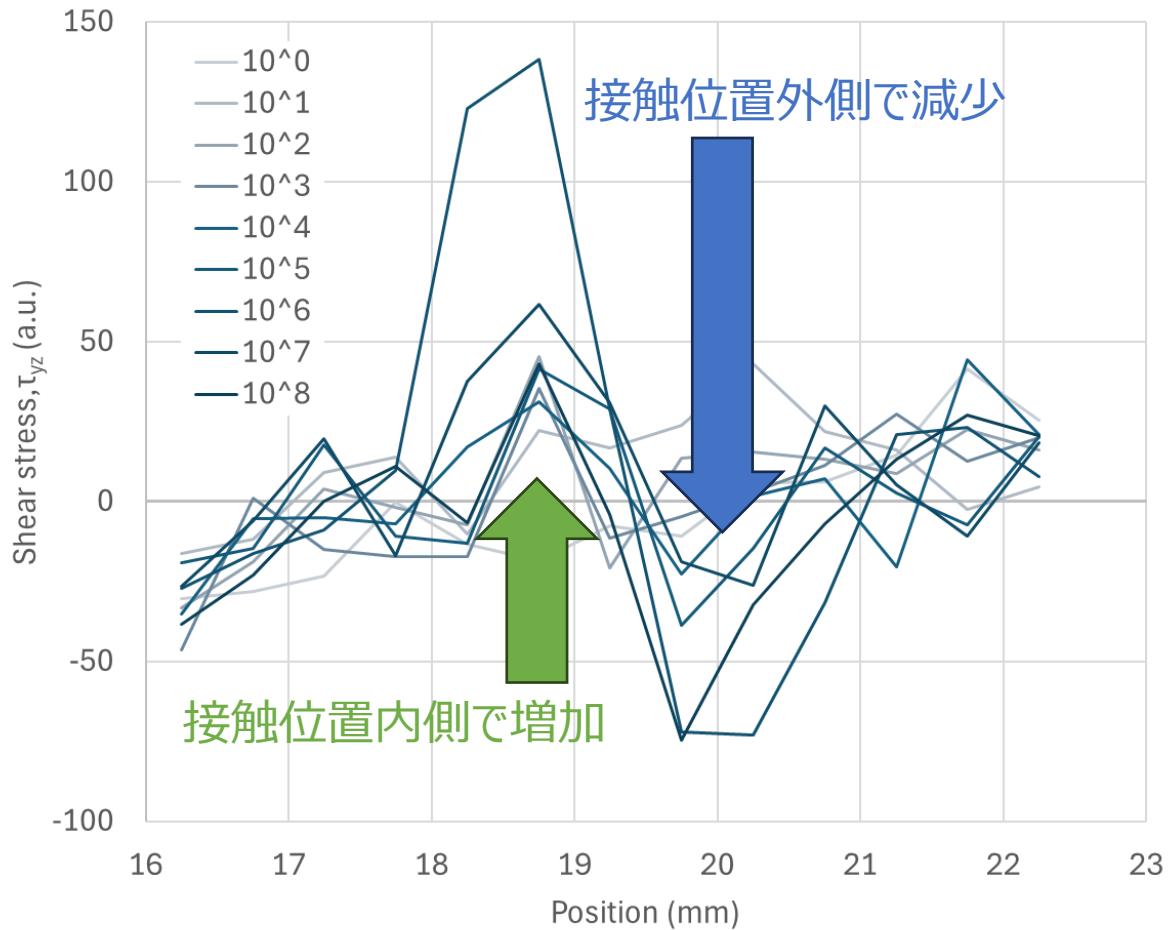
- スラスト荷重試験(556時間 : 10^8 回)を行い、平面応力・回折環半価幅を測定
- 応力値($\sigma_x, \Delta\sigma_x, \tau_{xy}$)と回折環半価幅を用いて、試験時間を回帰分析
- 重回帰分析、ランダムフォレスト回帰分析、多層パーセプトロン回帰分析を実施



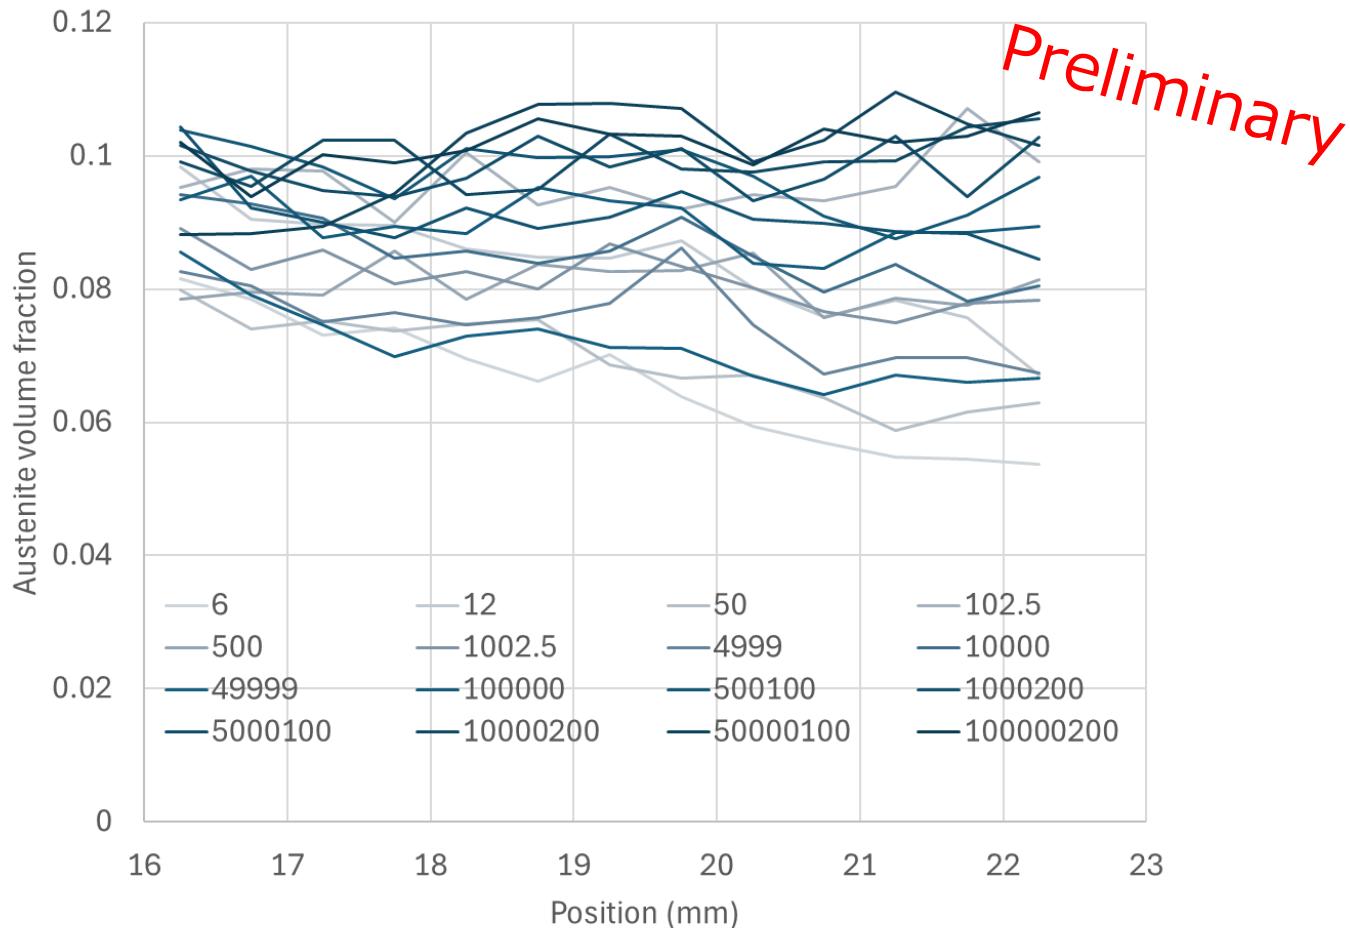
- 多層パーセプトロン回帰分析が最も精度が良い。
→三軸応力と残留オーステナイトを追加して、精度の向上を図る



- 通過回数が増加すると、接觸位置におけるミーゼス応力が減少
- 接触位置前後で、ミーゼス応力が増加



- 通過回数が増加すると、接觸位置内側におけるせん断応力が増加
- 接觸位置外側で、せん断応力が減少



- 接触位置における変化は見られない
- 測定位置や解析アルゴリズムに問題があり、正しく測定できていない可能性があるため、再度測定を実施する。

回帰分析とは

- 結果となる数値(目的変数: 通過回数)と要因となる数値(説明変数(ミーゼス応力、せん断応力)の関係性を求める。

線形回帰：変数の線形結合で表される。

- 単回帰分析 : $y = a + bx$
- 重回帰分析 : $y = a + b_1x_1 + b_2x_2 \cdots + b_nx_n$

非線形回帰：変数の非線形結合で表される。

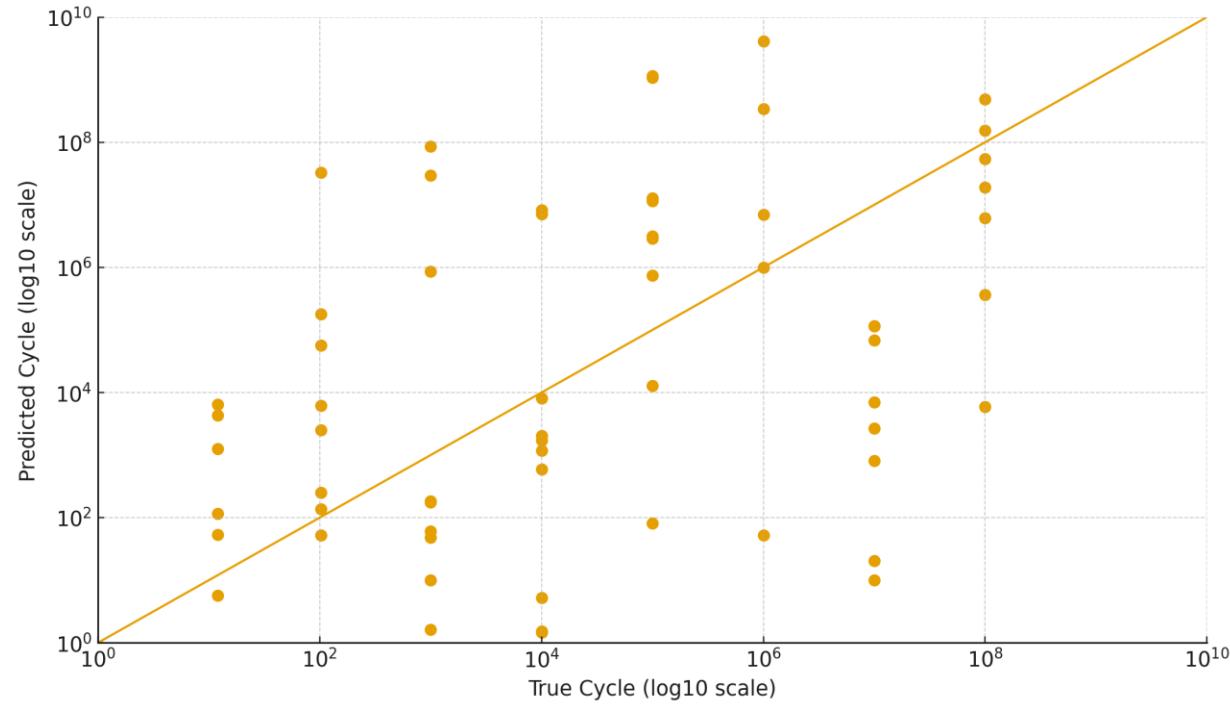
- ランダムフォレスト回帰分析
- 多層パーセプトロン回帰分析(MLP)

評価関数

- Log(RMSE) : 2乗平均平方根誤差

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Predicted_i - Actual_i)^2}{N}}$$

- 予測した通過回数と正解となる通過回数の関係を確認した。
- 半径方向の13点を1つのデータサンプルとして学習
- 完全に予測できていれば比例関係になる。(斜めの線に乗る。)
- $\text{Log(RMSE)}=3.34$ (5回平均)



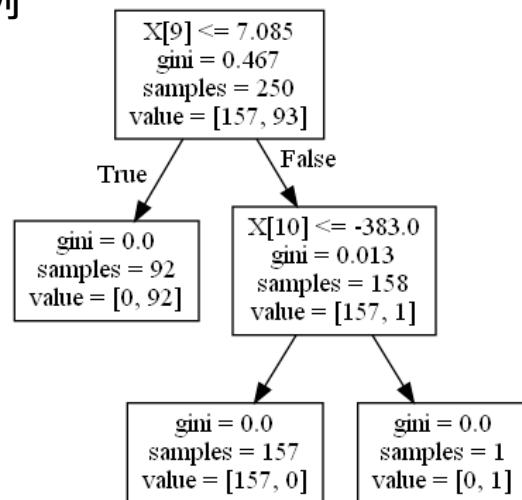
- 全体的にはばらつきが大きい

■ 決定木

- 最も精度が良くなるように条件分岐の条件を学習する。
- 5つの通過回数を上手く分ける条件を見つける。

回帰ではなく分類となる。

例

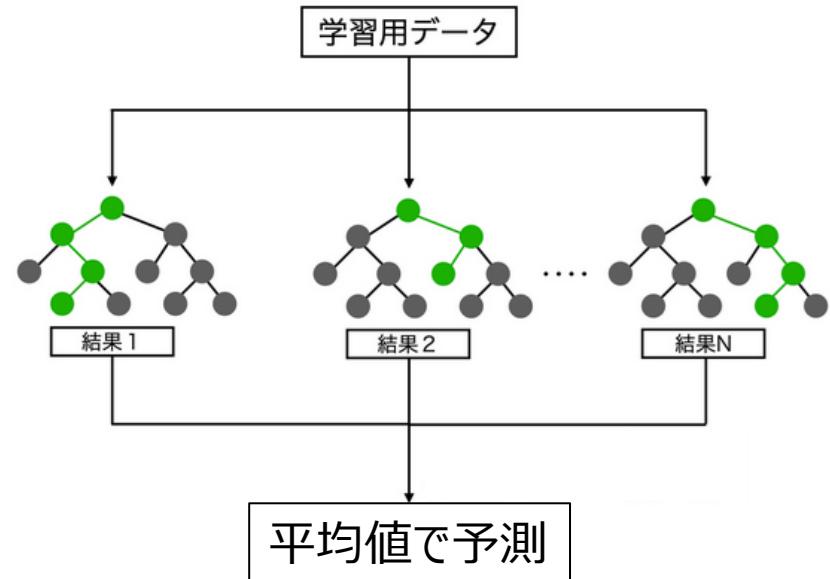


X[9] : 2点目の回折環半価幅
 X[10] : 3点目の残留応力

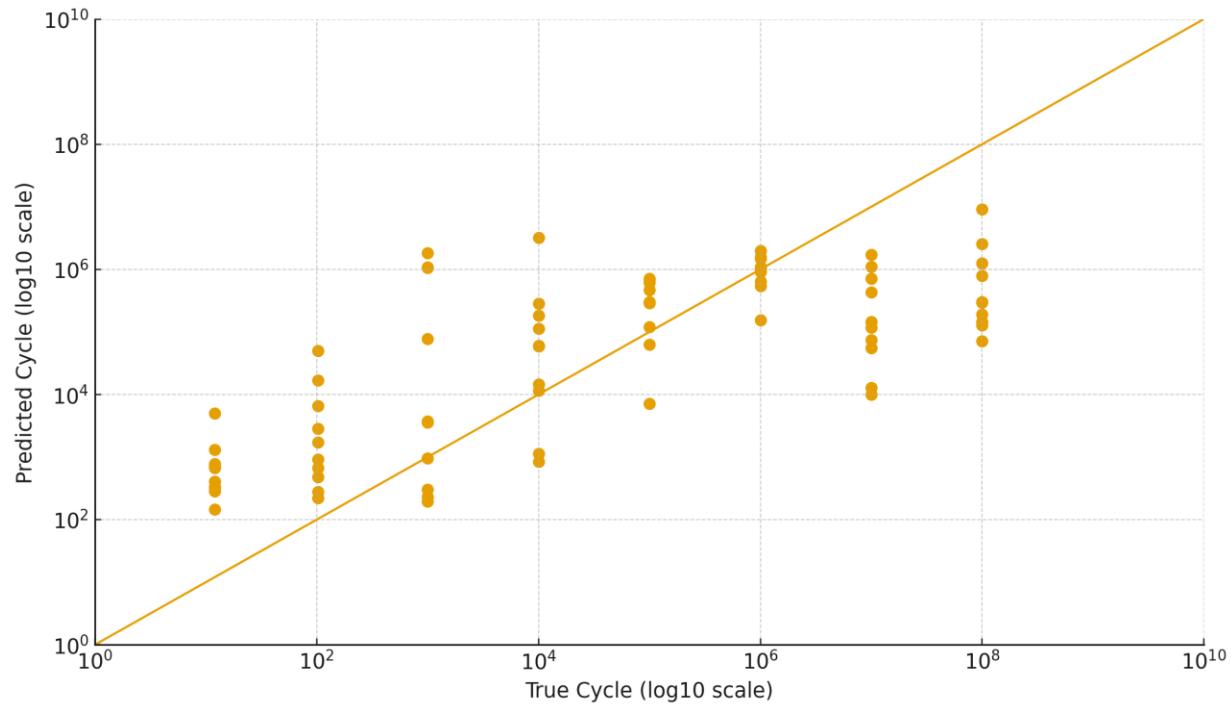
■ ランダムフォレスト

- 複数の決定木の平均値を予測値としてすることで精度を向上。

平均化することで連續値の予測が可能となり回帰分析できる。



- 訓練データとテストデータに分け、訓練データで回帰分析を行った後、テストデータを用いて予測値を確認した。
- $\text{Log(RMSE)} = 1.58$ (5回平均)



- 重回帰(3.34)より精度が良い

基本的なニューラルネットワーク

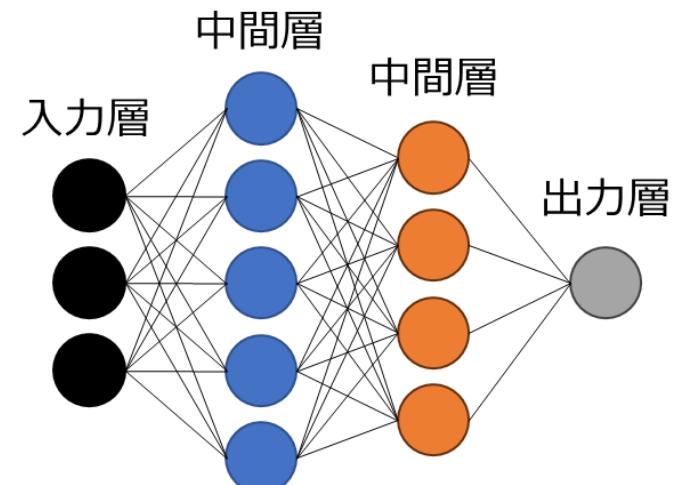
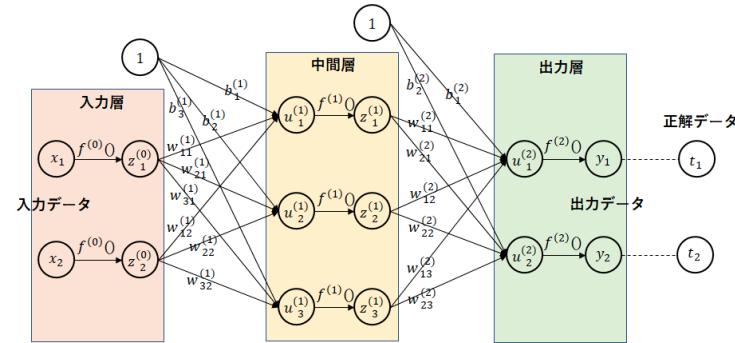
- 入力データ(行列z)に、重みwを掛け、バイアスbを足して、活性化関数fを掛け、次の層に出力。

$$u = f \left(\sum (z \cdot w) + b \right)$$

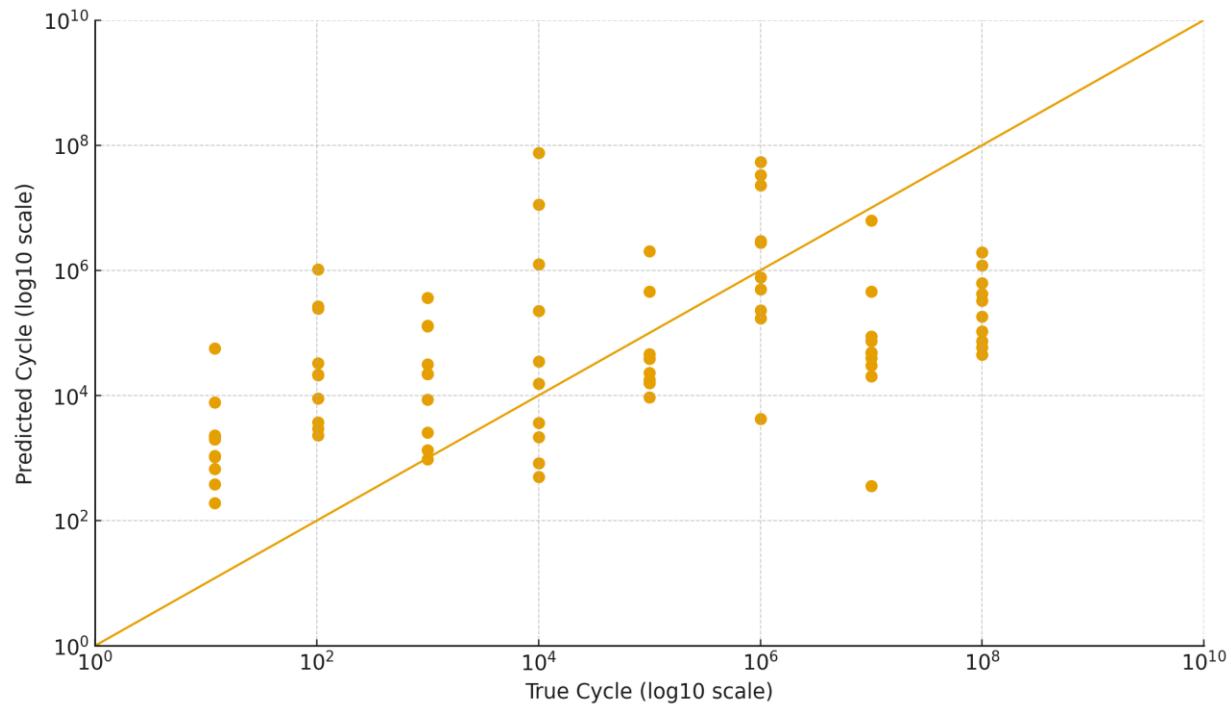
- ハイパーパラメータ(wやbの学習率、fなど)を調整して、損失関数を最小化する。

モデル

- 入力：10変数
 $(\sigma_{eq}, \tau_{yz}, \times \text{半径}5\text{点})$
- 出力：1変数(通過回数)
- 中間層：2層(1層目16ノード、2層目16ノード)



- 訓練データとテストデータに分け、訓練データで回帰分析を行った後、テストデータを用いて予測値を確認した。
- $\text{Log(RMSE)} = 2.00$ (5回平均)



- 重回帰(3.34)より精度が良く、ランダムフォレスト(1.58)より悪い

転がり疲労の定量的な評価のために、スラスト荷重試験を行い、三軸応力・残留オーステナイトの測定を実施し、測定データの統計的解析・機械学習により、鋼球通過回数の回帰分析を行った。

線形回帰である重回帰分析よりも、非線形回帰のランダムフォレスト回帰分析や多層パーセptron回帰分析のほうが精度が良かつた。

今後

- 残留オーステナイトの再測定
- 特徴量の作成
- パラメータやモデルの最適化