

機械学習を用いた車両情報と走行データに基づくエンジンオイル劣化予測

Machine Learning-Based Engine Oil Degradation Prediction Using Vehicle and Driving Data

シェル ルブリカンツ ジャパン (正) *大宮 尊 (正) 羽生田 清志 (正) 長富 悅史
 Takeru Omiya, Kiyoshi Hanyuda, Eiji Nagatomi
 Shell Lubricants Japan K.K.

1. はじめに

エンジンオイルの劣化は、エンジン部品の摩耗や腐食を加速させ故障や性能低下を引き起こす。近年のエンジンの小型化や物流需要の増加により、エンジンオイルの劣化挙動はより一層複雑化している。さらにこの複雑さは、都市部や高速道路での運転モードの違いによってさらに増し、正確なエンジンオイル管理が重要となっている。従来の時間基準保全 (Time-Based Maintenance: TBM) は定期的なオイル交換を行う手法であるが、実際のオイル劣化状態を考慮していないため、過剰なメンテナンスによるコスト増加や不十分なメンテナンスによるエンジン故障リスクを引き起こしている。そのため、オイルの実際の状態に基づくより効率的なメンテナンス手法が求められている。状態基準保全 (Condition-Based Maintenance: CBM) は、オイルの状態を継続的に監視し必要に応じてメンテナンスを行う手法であり、オイルの性状分析を通じて劣化状態を評価することができる。また、最新のオイル性状データに基づき、数学モデルを用いた予知保全 (Predictive-Based Maintenance: PBM) も可能である。しかし、エンジンオイルのサンプリングや性状分析にかかる時間と労力は依然として課題となっている。最近では、センサーを用いたオンラインでのオイル分析も注目されているがコストや設置に伴う課題があり、サンプリングやセンサー設置を不要とする新たなアプローチが求められている。本研究では、追加のサンプリングやセンサーを不要とし、車両情報と走行データを活用してエンジンオイル劣化を予測する新しいメンテナンスシステムを提案する^{1), 2)}。

2. 実験方法

本研究では、合計 169 台の商用車（54%がバス、46%がトラック）を用いた車両テストを 4 年間実施した。車両テスト期間に、計 820 回のオイルサンプリングとオイル性状分析を実施し、7 つの車両パラメータと 4 つのオイル性状パラメータを含むデータセットを作成した。車両パラメータには、車両情報としてバスかトラックかの車両タイプ、エンジンシリンダーの数、エンジン排気量[cc]、車両のサイズが含まれており、走行データとしては、エンジン総走行距離[km]、エンジンオイル使用距離[km]、月間走行距離[km]が含まれている。オイル性状パラメータには、塩基価[mg KOH/g](Base Number: BN)、残留炭素分[wt.%](Conradson Carbon Residue: CCR)、鉄分量[ppm] および 40°C での動粘度 [mm²/s]が含まれている。このデータセットを基に、80%のデータセットで回帰予測モデルを構築し、残りの 20%でモデルの評価を行った。サポートベクターマシン(Support Vector Machine: SVM)、ランダムフォレスト(Random Forest: RF)、およびガウス過程回帰(Gaussian Process Regression: GPR)の 3 つの異なる機械学習モデルを採用し、その精度を決定係数(R^2 値)で比較した。また、回帰モデルの説明変数の解釈性を理解するために、シャープレイ値を使用して各説明変数の重要性を比較した。これにより、エンジンオイル性状の予測に最も影響を与える変数を特定し、モデルの改善に役立てることができる。

3. 実験結果

3.1 回帰予測モデルの比較

SVM、RF、および GPR の回帰予測モデルを用いて算出された予測値と実際の値の比較を行った。**Figure 1** は代表として GPR によって算出された結果を示している。この図では、赤い点線が予測値と実測値の完全な一致を示している。また、実際の値と予測値の差異から計算された R^2 値の比較結果から GPR モデルが、全体的にオイル性状の予測において最も高い精度を示した。一方、SVM はすべてのパラメータにおいて R^2 値が最も低く、他のモデルに比べてパフォーマンスが劣ることがわかった。特に塩基価と残留炭素分に関して、GPR モデルは R^2 値が約 0.9 を達成し、非常に高い予測能力を示した。鉄分量および動粘度についても、 R^2 値が約 0.8 であり、良好な予測性能を示している。

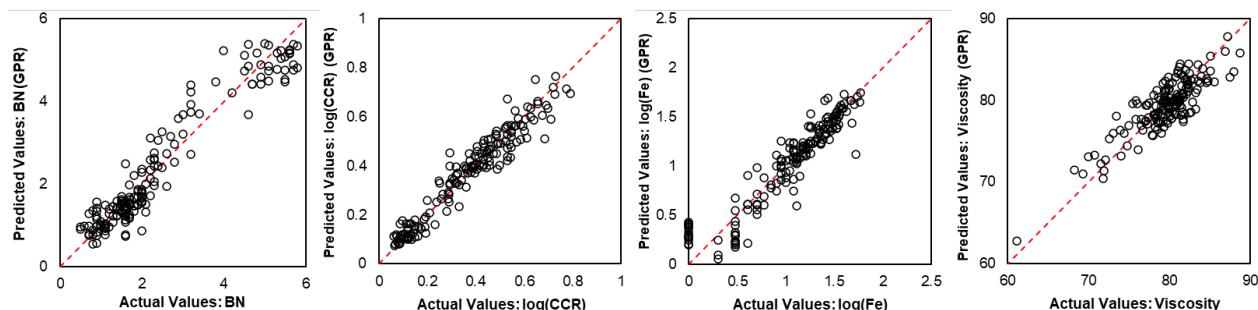


Fig. 1 Comparison of predicted values obtained by regression prediction models using GPR, and actual values.

既存の GPR 予測モデルを用いて、実測データが存在しない場合におけるエンジンオイル性状の劣化予測を行った。具体例として、エンジン総走行距離が約 300,000 km、月間走行距離が約 10,000 km の車両を対象とし、エンジンオイル使用距離が 60,000 km までの鉄分データを使用した。Figure 2 に、エンジンオイル使用距離が 80,000 km までの予測データを示す。この図では、黒い円が実測値を示し、赤い四角が予測値を示している。予測値は実測値とほぼ一致しており、60,000 km を超えるエンジンオイル使用距離においても、実測データが存在しない範囲で予測が可能であることが確認された。これにより、本研究で構築した GPR 予測モデルを用いて、データが存在しない場合でもオイル性状を外挿して予測できることが示された。このため、本劣化予測システムは、CBM のみならず、PBM にも活用できる可能性がある。

3.2 説明変数の解釈

GPR 予測モデルで使用した説明変数の解釈性を評価するために、100 のデータセットに対してシャープレイ値を計算した。シャープレイ値が大きいほど、予測結果への影響が大きいことを示し、水平軸上で広く分布する説明変数が重要とされる。この分析により、各説明変数が予測に与える影響を定量的に評価できる。Figure 3 は、BN と CCR におけるシャープレイ値の計算結果を示す。プロットの色が説明変数の大きさを示している。まず、BN とエンジンオイル使用距離(Oil Mileage)の関係において、BN 値が減少するとシャープレイ値が増加し、負の相関があることが確認された。さらに、他の説明変数に対する BN のシャープレイ値の分布が狭いことから、エンジンオイル使用距離以外の要因が BN に与える影響は小さいと考えられる。CCR の増加については、オイル使用距離が主な要因であるが、エンジン排気量(Displacement)との間に負の相関が見られる。これは、小排気量のエンジンが高負荷で動作しやすく、粒子状物質の排出が増加するためであると考えられる。BN、CCR の予測において、車両がバスかトラックか、または車両のサイズは比較的重要度が低いとされ、他の変数で説明可能であることが明らかとなった。

4. おわりに

本研究では、TBM や CBM の限界を克服する新しいエンジンオイルのメンテナンスシステムを提案し、その有効性を検証した。このシステムでは追加のオイルサンプリングを必要とせず、機械学習に基づく回帰モデルを用いて、車両情報や走行データからエンジンオイルの劣化を予測することができる。GPR モデルは、SVM や RF モデルと比較してオイル性状の予測精度が優れており、複数の説明変数を含むデータセットの複雑な関係を効果的に捉えている。これにより、走行距離や運転条件、エンジンタイプなど、複数の要因が絡み合うエンジンオイル劣化の予測に適していることが確認された。また、GPR モデルはデータが存在しない場合でも精度高くオイル性状を外挿し予測できることが示され、CBM および PBM の両戦略を支援する可能性があることが明らかとなった。さらにシャープレイ値分析により、エンジンオイル使用距離、エンジン排気量、エンジン総走行距離、および月間走行距離が BN、CCR、鉄分量などのオイル劣化指標に大きな影響を与えること示している。提案されたシステムは、エンジンオイルの劣化を監視・予測するための強力かつ効率的なソリューションを提供し、エンジンの最適な性能と寿命を確保するとともに、環境負荷と運用コストの削減に貢献することが期待される。

文献

- 1) 大宮 尊, 羽生田 清志 : エンジンオイル性状予測モデル生成プログラム及びこれによって生成されたエンジンオイル性状予測モデル (特開 2022-157881)
- 2) 大宮 尊, 羽生田 清志 : エンジンオイル劣化度判定方法、情報処理装置、エンジンオイル劣化度判定プログラム、(特開 2024-000340)

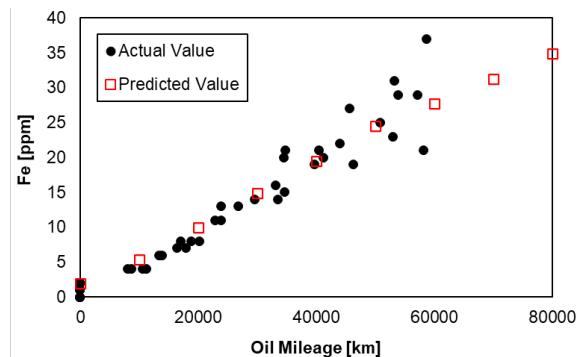


Fig. 2 Prediction using GPR up to 80,000 km for each engine oil property with total engine mileage of 300,000 km and monthly mileage of 10,000 km.

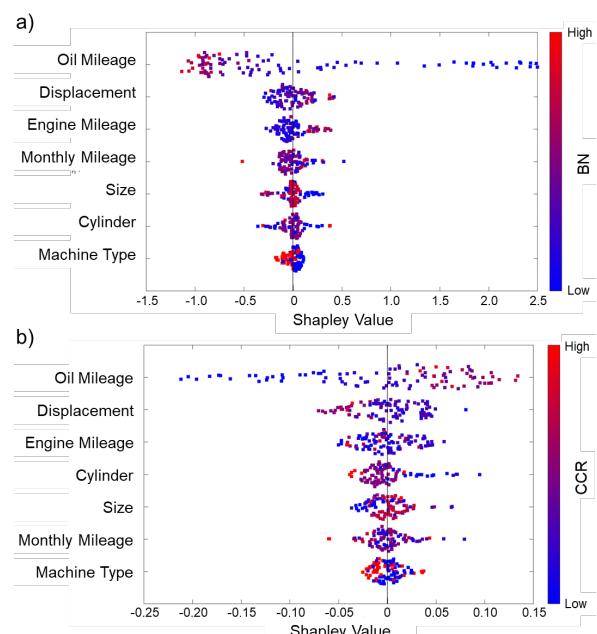


Fig. 3 Interpretation of (a) BN, (b) CCR by Sharprey values.