機械学習を使った専用工作機械の設計思考の可視化

51036005　鈴木紀彦

主指導教員　前田 恭伸教授
副指導教員　酒井 克彦教授

1. 研究背景

1.1. はじめに

専用機工作機械（以下専用機）とは工作機械の分類体系の一つで，量産される特定部品の特定部位の加工を行う機械である．汎用機では困難な加工工程を受け持つ専用機の設計は難しく，専用機メーカにはユーザの課題を解決するアイデア力や独創性が求められる．

1.2. 専用機の設計文化

除去加工を行う部品の寸法や形状の精度のほとんどは，工作機械の持つ回転や直線の運動精度と運動形態によって決められ，この特性は工作機械の母性原則[1]と呼ばれている．この原理より，オーダーメイドで製作される専用機は加工部品毎に都度最適な機能とかたちを設計する必要がある．これらの設計能力は短期間で習得できるものではなく過去の設計事例や熟練者からの情報に頼らざるを得ない場合が多い．機械に組み込む独自の要素技術は先人たちが発想と失敗を重ねて改善されてきたものが経験や感覚といった暗黙知[2]となっている．

1.3. 主軸の設計

主軸とは工作機械の構成要素の一部で，加工部品もしくは工具を取り付けて回転させる主要な構成要素である．専用機における主軸の設計では加工精度や加工時間が決められている場合がほとんどのため，それらの条件に的を絞った最適な構成を設計する．主軸の設計は構成する軸受の組み合わせ，はめあいや発熱対応などが複雑に絡み合っている．主軸を構成する部品は少なく，見掛けは簡単であるが，加工精度の安定した信頼性のある主軸を設計するには，加工の仕様から最適な軸受けの選定や潤滑方法までのシステム思考とノウハウの組合せで成立する．

2. 研究目標と目的

本研究では，工作機械の重要な要素である主軸の潤滑方法の選定について機械学習による分類と分析を行い，設計思考の可視化モデルを作る．暗黙知となっている技術を形式知とすることで，設計者にとっては技術のポイントをつかむための有用な指標となる．

3. データの取得と前処理

専用機メーカの過去の製作事例より主軸構成要素のデータベースを作成し，“主軸の潤滑方法”の選択について機械学習（決定木）による分析を行う．

主軸設計時に勘案する属性はさまざまあるが，その中で9つの属性を抽出し，計2543軸のデータを取得した．次に，データの前処理を行った．データは最初から分析できる形にはなっていない場合が多いため，各属性について，分析を行う前に削除や統合をした．

4. 決定木による分析

決定木とは意思決定や物事の分類を多段階にわたって行うとき，各段階での分岐を階層的な木構造で表現したものである．ディープラーニングのように判断基準がブラックボックス化していないため，その結果にいたる要因も理解しやすい．

4.1. 分析の手法

決定木の生成において，与えられたデータセットを最も良く分岐する属性をどのように選択するかが問題となる．本研究では，多分岐可能で情報利得比によって分割属性を選択する C4.5アルゴリズム[3]を採用した．決定木の生成にはC4.5が実装されたデータマイニングソフトWEKA[4]を用いた．

4.2. 学習モデルの評価基準

生成した学習モデルの評価基準は，混同行列の評価指数を用いた．

		判定された値（予測）	
		予測 +	予測 −
実際の値（正解）	正解 +	TP（真陽性）	FN（偽陰性）
	正解 −	FP（偽陽性）	TN（真陰性）

- 正解率(Accuracy):正や負と予測したデータのうち，実際にそうであるものの割合．
- 再現率(TP Rate):実際に正であるもののうち，正であると予測されたものの割合．
- 偽陽性(FP Rate):実際に負であるもののうち，正であると予測されたものの割合．

4.3. 次元削減（属性削減）

8つの説明変数（属性）の数を減らすために，組み合わせによる評価指数の違いを確認する．目的変数（軸受の潤滑方法）への影響の小さい説明変数は削除し，シンプルな木の生成のために，64通りの学習結果より，3つの説明変数を抽出した．

4.4. 枝刈りとパラメータの決定

決定木では，より多くの枝や葉を発生させると分類精度も向上する傾向にあるが，それに伴って生成された決定木が複雑になる．そこで，できるだけ少ない枝や葉で，できるだけ分類精度が低下しないような決定木生成を目指して，枝刈りと呼ばれるパラメータ調整を行った．

WEKAによる決定木生成には2つのパラメータ（M: 葉における最小事例数，C: 枝刈りの信頼度）がある．これらを組み合わせて決定木の評価を行った．
パラメータ調整により得た結果を表1と図1に示す．

表1　決定木の分類精度

M	C	葉数	木の大きさ	正解率 %	TP Rate (平均)	FP Rate (平均)
3	0.15	67	127	87.256	0.873	0.059

4.5. 決定木結果の図示

学習結果より各軸受のクラスごとのdn値による上限シキイ値を図示(図2)した.

シキイ値は横軸に主軸径d(mm), 縦軸に回転数n(min^{-1})の図に反比例曲線で表される. 図中の塗りつぶし範囲は採用実績の範囲を, プロット点は採用実績を表す.

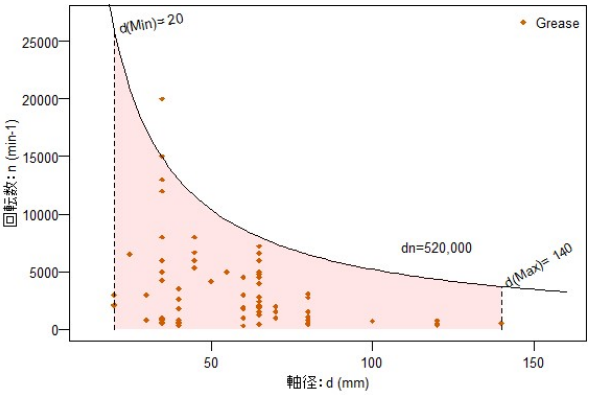

図2　シキイ値を図示した一例

5. 考察

学習結果より, 属性の多さがが必ずしも分類の精度を飛躍的に向上させているとは限らない. また, 属性の多さは決定木の複雑さ(葉数や木のサイズ)に関連しているとは限らないことを確認した.

取得した属性より説明変数として3つの属性に削減し, パラメータを決定した. 結果, 決定木全体の正解率は87.3%となった. さらに, 各軸受のクラスごとの評価も行い, 暗黙知となっている上限シキイ値を判別し図示した. これらの図より, 各設計者は設計過程の中で過去の実績に基づいた適正な潤滑方法を選定することができる. さらに, 図示した決定木結果は設計者に評価され, 暗黙知なっている設計思考の可視化の重要性を再確認した.

本研究の目的は設計者の思考を機械学習によって可視化することである. 本研究では専用機主軸の潤滑方法の決定についてのみを扱ったが, 主軸の設計データだけではなく, 他の機械要素の属性もデータ化していくことで, 機械学習による分析が可能になる. これらは各設計者のカンやコツや経験といった暗黙知を他者に伝えるためのツールとして, または若手設計者が企業のノウハウを理解するための形式知として役に立つと考えられる. また過去の事例を見直すことで, 未知の使用領域や研究が必要な領域を発見することも可能となるであろう.

6. 今後の課題

本研究の機械学習による課題としては分類精度の向上が考えられる. 取得した以外の属性を組み合わせることによる分類精度向上の検討が必要である. また, C4.5やCARTアルゴリズムによる決定木では属性中のクラスの不均一さに大きく影響され, データ数が少ないクラスはデータ数の多いクラスの影響を受け, 分類精度が落ちてしまうことが知られている[5][6]. 他の決定木アルゴリズムや集団学習などの手法を用いて分類精度の比較を行うことで最適な分類手段をみつけることができるであろう.

参考文献

[1] 佐久間敬三:“工作機械”,コロナ社, pp.67(1992年)

[2] 野中郁次郎:“知識創造企業”,東洋経済新報社, pp.9 (1996)

[3] 金　明哲: “Rと判別分析”,ESTRELA,No.129,pp.67(2004)

[4] Eibe Frank, Mark A. Hall, and Ian H. Witten (2016). The WEKA Workbench. Online Appendix for ″Data Mining: Practical Machine Learning Tools and Techniques″, Morgan Kaufmann, Fourth Edition, 2016.

[5] 峰岸達也,新美礼彦,小西修:“不均一データストリームのためのオンライン決定木のノード構築アルゴリズムの提案と評価”, 第3回データ工学と情報マネジメントに関するフォーラム(DEIM2011)

[6] David A. Cieslak and Nitesh V. Chawla: Learning Decision Trees for Unbalanced Data, ECML PKDD 2008 Machine Learning and Knowledge Discovery in Databases, pp.241-256,2008

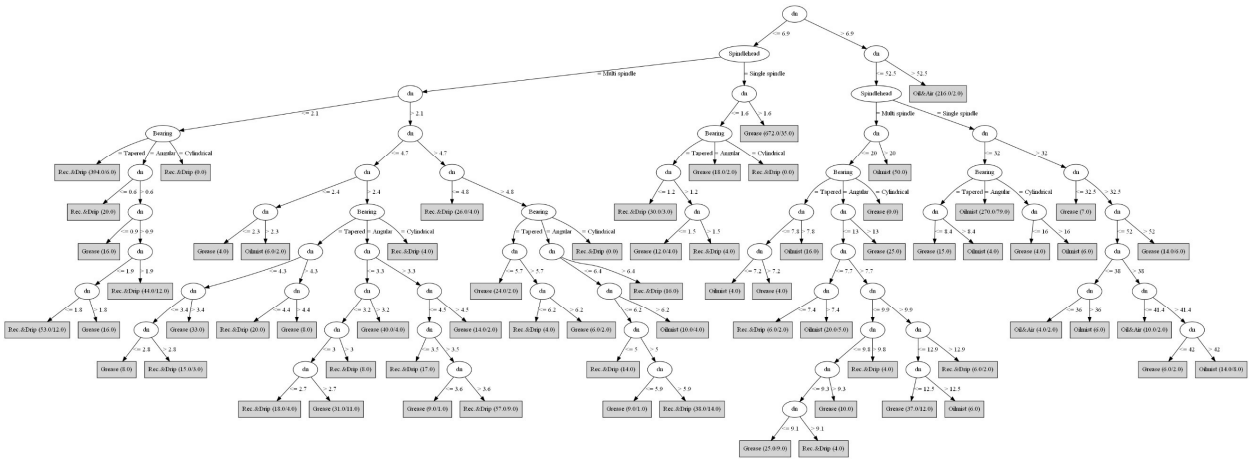

図1　生成された決定木