

Markov Logic Network による機械加工因子間の確率推定

Probability Estimation on Machining Factors with Markov Logic Networks

佐々木 裕^{*1} 三輪 誠^{*1} 古谷 克司^{*1}
Yutaka Sasaki Makoto Miwa Katsushi Furutani

原田 博正^{*2} 寺本 一成^{*2}
Hiromasa Harada Kazunari Teramoto

^{*1} 豊田工業大学
Toyota Technological Institute

^{*2} (株)豊田中央研究所
Toyota Central R&D Labs., Inc.

This report describes an approach to the descriptive learning over machining knowledge bases given in the form of the first-order logic and estimation of a probability of any logical relation among machining factors. To our best knowledge, there are no studies that estimate probabilities of machining knowledge in the descriptive learning approach using Markov Logic Networks. To evaluate the quality of the estimated probabilities, we created a predicative problem which is to select a tool material suitable for a given work material under several machining conditions. Experimental results confirmed that our approach achieves a Top 1 accuracy of 0.46 and an MRR of 0.67.

1. はじめに

近年、深層学習等の機械学習技術に注目が集まっているが、殆どの機械学習の研究は、predictive な学習を対象としている。predictive な学習は、特定の入力に対する特定の出力を予測するモデルを構築する教師あり学習である。一方、descriptive な学習は、教師なし学習の一種であり、特定の目的を持たず、与えられたデータ全体をうまく説明するモデルを学習する。このようなモデルを構築することで、学習したモデルを様々な問題の解決に利用することができる。本研究では、機械加工知識を論理式により記述し、Markov Logic Network (MLN) [Richardson 2006]により、知識全般に対する確率を推定し、因子間の任意の論理関係の確率を計算するアプローチを提案する。

2. Markov Logic Network (MLN)

2.1 MLN の概要

MLN は、スコアレム連言標準形(節集合)で与えられた知識に対して確率の推定を行う。各論理式(節)の確率を推定するのではなく、可能世界(Herbrand 解釈)に対する確率を推定することが特徴である。MLN は、知識ベース $KB = \{F_1, \dots, F_i, \dots, F_n\}$ (F_i は論理式、本研究では節)が与えられたとき、可能世界 x の確率 $P(X=x)$ を対数線形モデルにより下記のように表す。

$$P(X = x) = \frac{1}{Z} \exp \left\{ \sum_i w_i n_i(x) \right\}$$

ここで、 Z は正規化項、 $n_i(x)$ は x において論理式 F_i の基礎例が真となる個数、 w_i は $n_i(x)$ に対する重みである。知識ベースに関数記号が含まれる場合は、関数記号の埋め込み深さを制限することで Herbrand 領域を有限の範囲に抑える。

w_i の学習は、 P の対数尤度に関する下記の勾配により w_i を更新することで実現される。

$$\frac{\partial}{\partial w_i} \log P(X = x) = n_i(x) - \sum_{x' \in W} P(X = x') n_i(x')$$

ここで R w_i は L2 正則化項、 R は正則化パラメータ、 W は可能世界の集合である。

スコアレム連言標準形で表現された任意の論理式 f の確率

は、その論理式が真となる可能世界 x の確率の和である。

$$P(f) = \sum_{x: \models f} P(X = x)$$

このように学習されたモデルにより、学習データに含まれる述語と関数、定項(またはソート)からなる論理式であれば、どのような論理式の確率も計算できる。

2.2 ソートによる可能世界の制限

我々の作成した MLN システム OSMLN(Order-Sorted MLN)では、可能世界を制限するためにソートの情報を活用する。ソートを下記の形式で定義する。

$$s > s_1, s_2, \dots, s_n$$

これは、 s が下位のソートとして s_1, s_2, \dots, s_n を持つことを意味する。述語記号に対しては、引数のソートを定義することで、Herbrand 世界において述語の取りうるソートを制限する。

さらに、引数に排他ソート宣言を新たに導入する。引数を排他ソートと宣言すると、その引数で取りうるソートの1つだけでその述語が真になるよう可能世界を制限する。例えば、被削材として、圧延鋼と炭素鋼が存在するとき、被削材は2つのどちらかであり、両方ということは起きないので、排他ソートにより原子論理式「被削材(圧延鋼)」と「被削材(炭素鋼)」のどちらかが真になる可能世界しか許さないようにする。これにより可能世界の数を劇的に削減できる。

このような制限をつけても可能世界の数は、述語とソートに関する組み合わせ数に対して指数的に増加するため、可能世界を特定の個数サンプリングすることで実用時間内で計算可能にする。具体的には、Herbrand 世界の要素にランダムに真偽値を割り当てながら、 N 個の Herbrand 解釈 (=可能世界)を生成することで、可能世界をサンプリングする。

3. 機械加工知識

機械加工により意図する性能を実現するためには、加工に関連する多様なパラメータを調整する必要があるが、機械加工の現場では個々の工作者が持つ経験知識に基づいて加工を行っているのが実情である。これは、工具・被削材の材質・形状、刃の形状・角度、環境条件、要求条件等様々な要因により最適な加工パラメータが変化するため、あらゆる場合を数理的に解析することが有効なアプローチでないためである。機械加工に

関する知識は、機械分野の専門家が作成した。知識は、2 つの直接影響しあう因子間の関係を記述したものである。

切削条件は、高能率化、高品位化、低コスト化の 3 種類を対象とする。工具材質は、ボラゾン、超微粒子超硬合金、超硬、ハイスの 4 種類を対象とし、被削材質は、圧延鋼/無処理、炭素鋼/無処理、炭素鋼/焼入れ焼戻し等の 21 種類を対象とする。加工因子として、高温硬度、耐摩耗性、耐欠損性、切削力、切削温度等の 33 種類を対象とする。

MLN は直接的に連続値を扱えないため、因子間の関係は、離散化した尺度により結びつける。離散化は、各尺度に対するレンジ分けにより実現する。たとえば、低コスト化の度合いは、小、やや小、中、やや大、大の 5 段階に分け記号で表す。離散化の段階数は、対象により 2~7 段階で表す。

たとえば、低コスト化と工具材質の関係の定義は下記の通り。

- 低コスト化(小) → 工具材質(ボラゾン)
- 低コスト化(やや小) → 工具材質(超微粒子超硬合金)
- 低コスト化(中) → 工具材質(超硬)
- 低コスト化(大) → 工具材質(ハイス)

ただし、要求条件を「低コスト化を大」にしても、被削材質等により工具寿命が短くなるなどの影響を受けるため、最適な工具材質は常にハイスではない。MLN は、純粋な論理推論とは異なり、与えられた知識全般に対して尤もらしい確率を付与するため、矛盾を含む知識であっても扱うことができる。たとえば、21 種類の被削材に対して、「低コスト化が大」を要求条件としたとき、ボラゾンが正解となる回数は 0 回、超微粒子超硬合金は 8 回、超硬は 6 回、ハイスは 7 回であり、常にハイスとなるわけではないが、このような場合も MLN であれば扱うことができる。

2 つの因子が連続値を取る場合に、因子間に正または負の相関関係がある場合は、

- ワーク材熱伝導率(小) → 切削温度(高)
- ワーク材熱伝導率(大) → 切削温度(低)

のように離散値間の関係を列挙する。

4. 実験

4.1 実験設定

切削加工に関する知識を論理式として記述し、述語種類 33、関数記号 0、ソート種類 33、上位ソート 8 からなる知識ベースを構築し、OSMLN により確率を付与した。

descriptive な学習を行うことが目標であり、予測問題を解くことは本来の目標ではないが、学習された確率の妥当性を確認

するために、以下のような評価実験を行った。ただし、ここでは教師あり学習は行っていない。正解は与えず、知識全体に対する対数尤度を最大化する教師なし学習を行っている。

3 種類の切削条件の下で、21 種類の被削材質に対して、4 種類の材質の中から最適な工具材質を選択する問題を設定し、1 位正解率 (Top 1) および、平均逆順位 MRR (Mean Reciprocal Rank)により評価する。可変パラメータは、正則化パラメータ R である。

4.2 結果と考察

実験結果を表 1 に示す。サンプリング数は 10,000 とした。結果のばらつきはあるが、教師なし学習にも関わらず、Top 1 の精度で概ね 38~46%を実現できており、4 択問題のベースラインの 25%を大幅に上回っている。評価では正解を最適な材質としたが、実際には 2 位でも正解と見なせる場合もあり、実質的な正解率はもう少し高いと考えられる。MRR は 0.62~0.67 程度が得られた。

MLN による確率推定の安定と高速化のため、今後サンプリング法の改善が必要である。また、descriptive な学習であるため、性能が正則化パラメータにより影響されることが予備実験を含めた実験を通じて確認されている。

5. おわりに

MLN により機械加工知識の全体に整合する確率を付与する手法を提案した。評価のために工具材質の選択問題を設定し、実験を行った。良好な予測性能が得られたことから、MLN により妥当な確率が付与されていることが裏付けられた。今後、機械加工知識の確率推定性能を向上させるとともに、加工知識ベースシステムを構築していく中で、因子間の確率を寄与度として活用する方法を明らかにしていきたい。

謝辞

本研究で使用した OSMLN は、第一著者が 2013 年に CEDER プロジェクトの客員教授としてフランス Lyon 大学に招聘されたときに作成したプロトタイプ [Sasaki 2013] が基礎になっている。Lyon 大学での研究の機会を与えてくれた Hassan Ait-Kaci 教授に深く感謝する。

References

- [Richardson 2006] Matthew Richardson, Pedro Domingos. Markov Logic Networks, Machine Learning, 62(1-2):107-136, February 2006.
- [Sasaki 2013] Yutaka Sasaki, An Effect of Ordered Sorts in Markov Logic Networks, CEDER Technical Report 6, 2013.

表 1 工具材質の予測評価結果

正則化	高能率化		高品位化		低コスト化		総計	
	Top 1	MRR	Top 1	MRR	Top 1	MRR	Top 1	MRR
0.01	0.5238	0.7143	0.3333	0.5992	0.3810	0.6230	0.4127	0.6455
0.02	0.5238	0.7063	0.3333	0.6071	0.4286	0.6508	0.4286	0.6548
0.03	0.5238	0.7064	0.3810	0.6230	0.3333	0.6349	0.4127	0.6548
0.04	0.4762	0.6825	0.3810	0.6230	0.5238	0.7183	0.4603	0.6746
0.05	0.4286	0.6548	0.3333	0.5992	0.5714	0.7302	0.4444	0.6614
0.06	0.4286	0.6468	0.3810	0.6230	0.4762	0.6944	0.4286	0.6548
0.07	0.4286	0.6468	0.3810	0.6230	0.4762	0.6944	0.4286	0.6548
0.08	0.4286	0.6389	0.3810	0.6310	0.4286	0.6627	0.4127	0.6442
0.09	0.4286	0.6389	0.3810	0.6310	0.4286	0.6627	0.4127	0.6442
0.10	0.4286	0.6270	0.3810	0.6310	0.3333	0.6071	0.3810	0.6217