

ILP を用いたダイス製造プロセスネットワークの予測

Using ILP for predicting process network in dies production

藤村 祐輔*¹ 松井 藤五郎*² 大和田 勇人*² 中島 和彦*³
Fujimura Yusuke Matsui Tohgoroh Ohwada Hayato Nakajima Kazuhiko

*¹東京理科大学大学院理工学研究科経営工学専攻

Department of Industrial Administration, Faculty of Science and Technology, Tokyo University of Science

*²東京理科大学理工学部経営工学科

Department of Industrial Administration, Faculty of Science and Technology, Tokyo University of Science

*³株式会社 東宝ダイス製作所

Toho Dies Co.,Ltd, Director and General Manager

While a number of remarkable applications have been explored using ILP-based machine learning, we focus on an industrial application in which metal molds (called dies) are produced for devices in automotive. In this application, ILP is used to automatically construct a process network in dies production. The process network can be viewed as a exible assembly line where tailor-made dies are manufactured in order to satisfy client 's requirements. An ILP-generated hypothesis determines which processes are needed to produce dies.

1. はじめに

近年、機械学習の分野において帰納論理プログラミング (ILP) を用いた研究は様々な領域で盛んに研究が行われている。本研究では、ダイスと呼ばれる金型製造の産業アプリケーションに焦点を当てた。ダイスとは、車や船、バイク等の機械の部品として主に使われている金型である。しかし、自動車等の製造業の根底にあるのは金型産業であるにもかかわらず、日本のダイス製造会社の 90% 以上は作業員が約 20 人程度の中小企業であるというのが現実である。1 日に 200 件を超えるクライアントからの注文に対して、専門家の作業員により全てテーラーメイドで異なる形のダイスが作られる。そのため、少人数の作業員で成り立つ中小企業にとってはたくさんのプロセスから成り立っているダイスの製造プロセスを 1 つ 1 つ設計していくのは非常に手間がかかるといった問題が挙げられる。

この問題を解決するために学習機能を持った製造工程予測システムを構築する。新規の注文は来た際に過去のデータからシステムが自動的に製造工程を予測できれば、このような手間が省け、またクライアントからの注文も容易に満足できると考えられる。

我々はこれまでに、ILP を用いてダイスを製造工程ごとに分類する方法を開発してきた [2] [3] [4]。そこで、本論文では設計書などの過去のダイス製造データから製造工程を導くために、機械学習の手法の一つである ILP を用いて導き出されたルールがダイスを製造する際にどの工程を通過していくかを実際に予測する。

2. 手法

2.1 ILP とは

本研究では、ILP (inductive logic programming) を用いて過去の注文データから新規に注文されたダイスの製造に必要

なプロセスを予測するためのルールを学習を行う。ILP とは論理プログラミングに従って帰納推論を行う枠組みである。ILP の特徴として、一階述語論理を扱う事が出来る事から、属性値の集合では表現出来ない関係表現を学習する事ができ、また一階述語論理で記述された背景知識 (background knowledge) を学習システムに与えられる。これより ILP システムに複雑なルールを学習させる事が出来る。よって、ダイスに関しても製造工程間の関係を記述でき複雑なルールを学習することが可能である。

2.2 作成述語

今回使用する述語として、[2] で作成した述語を用いる。まず、ダイスの特徴を示す述語が挙げられる。図 1 は、典型的なダイスの構造を示している。図 1 のダイスは、ドリルを使ってダイスの表面を削るフライス加工やワイヤーを使用して穴を貫通させるワイヤー加工、貫通させない穴を開けるための放電加工等といった作業が施されており、またダイスの円筒の中心部分における穴の形は六角形であるといったことが分かる。

本研究の目的は、クライアントから要求される注文特性に関して、各々のダイスの製造工程パターンを予測することであるので、送られてくる注文に対するダイスの特徴を背景知識として使用する。背景知識の例として以下のようなものがある。

- $shape(A,B)$. 事例 A の穴の形は B である。
- $has_wire(A)$. 事例 A はワイヤー加工が必要である。
- $height(A,B)$. 事例 A のダイスの高さは B である。
- $big_hole(A,B)$. 事例 A の大穴の直径は B である。

本研究におけるゴールとして工程間の前後関係を求めることは必要不可欠である。東宝ダイス製作所の設計書よりダイスにおける作業工程は全部で 20 種類ある。そこで $process_i(A,B)$ という述語を用いた。ここで A はダイスの事例番号, B は作業工程を表している。また, i はプロセスの作業手順を示す。具体的に言えば、プロセスネットワークを構築していくにあたってまずはどの工程を始めに通過するかを求める必要がある。そ

連絡先: 連絡先: 藤村 祐輔, 東京理科大学大学院理工学研究科経営工学専攻, 千葉県野田市山崎, 2641, j7407622@ed.noda.tus.ac.jp




図 1: 典型的なダイスの構造

ここで、始めに通過する工程を $process_1(A,B)$ と定義する。始まりの作業工程が学習されたならば、続いては 2 番目に通過する工程を求めるため $process_2(A,B)$ と定義し学習する。よって、 $i - 1$ で求めた作業工程の次の工程を求めるために i を順に増やしていき学習を行わせる。このようにして、作業の始まりから順に次の作業を求めていき、それらを組み合わせてあげることによりダイスの製造プロセスネットワークを構築することができる。

3. 予測

3.1 ルールの生成法

本研究ではルールを得るため Progol を使用した。本実験で用いたダイスの事例数は 40 である。 $process_1(A,B)$ ではあるダイスにおいて始めに行われる作業を正事例とし、それ以外はすべて負事例とするので、正負事例の数はそれぞれ 78, 722 である。 $i = 1$ を除く $process_i(A,B)$ では作業順序 $i - 1$ 番目に求められた作業の次の作業工程だけを正事例とし、それ以外は全て負事例とするので、正負事例の数は各プロセスごとに実際は異なるがそれぞれ約 40, 760 である。

$process_1$ から始まり、 $process_2, process_3...$ と順に Progol を実行した。ここでは、 $process_1, process_2$ において結果として得られたルールの例を以下に示す。

[$process_1$ で得られたルールの例]

```
process_1(A,wire):- has_wire(A).
process_1(A,harsh_lathe):-big_hole(A,low),width(A,high).
```

[$process_2$ で得られたルールの例]

```
process_2(A,honing):- small_hole(A,mid).
process_2(A,honing):- has_discharge(A),small_hole(A,low).
```

同様に、 $i = 1, 2$ 以外の $process_i$ についても十分のルールが導き出された。求められたルールを組み合わせることにより、ダイスの製造プロセスネットワークを導くことが出来ると考えられる。

3.2 予測精度の測定法

分類精度の測定には Leave-one-out を用いた。Leave-one-out により得られた各プロセスごとに学習したルールの分類精度を図 2 に示す。棒グラフの下にあるそれぞれの番号はそれぞれ工程順序を示し、三本の棒グラフは左から Accuracy, Precision, Recall を表している。 $process_1$ では Accuracy は 95.3%, Precision は 88.5%, Recall は 59.0% となった。 $process_2$ では Accuracy は 99.3%, Precision は 94.6%, Recall は 92.1% となった。 $process_3$ では Accuracy は 94.6%, Precision は

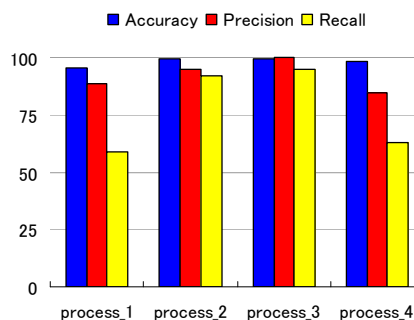


図 2: 各プロセスごとに学習されたルールの予測精度

100%, Recall は 94.6% となった。 $process_4$ では Accuracy は 98.4%, Precision は 84.6%, Recall は 62.7% という記録を結果した。

4. 考察

各プロセスごとにダイスのどの作業工程を通るかが予測された。各プロセスごとに得られたルールを組み合わせることでダイス全体の製造プロセスネットワークを導くことができる。本実験で得られたルールによるプロセスネットワーク自体が未知のダイスに対してどの程度有効であるかを検証する必要がある。

そこで、全プロセスにおける Accuracy, Precision, Recall についてそれぞれ比較してみる。Accuracy については、全プロセスにおいて 95% 以上であるため十分高い精度で予測できているといえる。Precision についても、かなり高い精度であるということが分かる。今回学習されたプロセスは十分の信用性があるといえる。Recall については、 $process_2$ と $process_4$ などにおいて精度が十分でないプロセスがみられた。

ここで、Precision が高い学習法と Recall が高い学習法について考えてみる。Precision が高い学習法とは学習の制約がきついため、新規の注文がきた際にコンピュータが学習したダイスの製造工程パターンは工程の見逃しがある恐れがあるが、誤分類は少ないといった特徴が挙げられる。また、Recall が高い学習法とは学習の制約がゆるいため、新規の注文がきた際にコンピュータが学習したダイスの製造工程パターンは誤分類は含まれるが、工程の見逃しは少ないといった特徴が挙げられる。後に専門家が学習された製造工程パターンをチェックするにあたって Precision が高いシステムより Recall が高いシステムの方が容易にチェックできると考えられる。よって、今後の展望として Recall の精度を上げる学習法の提案が必要となる。

5. まとめ

本論文では、ILP を用いてダイスを製造する際にダイスの持つ特性によりどの作業工程を通過するかどうかを予測する手法を提案した。Progol を用いた実験の結果より各プロセスごとにどの製造工程を通過するかを予測できた。また、全プロセスの予測精度については今後 Recall の精度を上げなければいけないといったことが考えられる。

参考文献

- [1] S. Muggleton : Inverse entailment and progol, New Generation Computing, Vol. 13, pp. 245.286,(1995)
- [2] 藤村, 松井, 大和田, 中島 : ILP を用いたダイス製作プロセスネットワークの学習. 情報処理学会 (2008)
- [3] 山崎, 松井, 大和田, 中島 : ILP を用いたダイス製作プロセスネットワークの構築. 人工知能学会 (2007)
- [4] Yamazaki, Matsui, Ohwada, Nakajima : Using ILP for constructing process network in dies production. International Conference on Inductive Logic Programming(2006)
- [5] 古川, 尾崎, 植野: 帰納論理プログラミング, 共立出版 (2001)