

## 眼底写真による緑内障診断規則の学習\*

6G-3

溝口 文雄† 大和田 勇人† 大導寺 牧子† 白土城照‡

†東京理科大学 理工学部

‡東京大学医学部眼科学教室

## 1 はじめに

人間の柔軟な判断力や複雑な分類能力を機械にもたせることは、人工知能研究の目標の一つであろう。

機械学習はデータという経験からルールという判断力を得る手法であり、その中で帰納論理プログラミング (ILP) はあらかじめ背景知識を与えることで、効率的にデータ間に存在する関係を記述することが可能である。

しかし、与える背景知識によって学習の精度、得られるルールが変わってしまうため、考慮が必要である。

本研究では、適用例として緑内障の診断規則の学習を取り上げ、専門医がどのようにして診断を行なうかといった経験則を背景知識に取り入れて、専門医が診断を行なった 39 枚の眼底画像から専門医のもつ診断知識をルールとして具体化するため、学習されたルールを背景知識として用いることで学習ルールの無駄な探索を避け、逐次学習 [1] で可能となったような階層的なルールを得ることを目的とする。

## 2 ルールの背景知識への適用

## 2.1 背景知識

ILP は、学習したい概念 (学習ターゲット) を与えられた背景知識で説明するルールを導出する。学習器 GKS[2] は、学習の過程でターゲットに関係する全ての背景知識から、グリーディーに探索を行なう。従って、もし背景知識に有効でないデータが含まれているとしたら、無駄な探索を行なってしまっただけでなく、精度の低いルールが導出されてしまう。そこで、GKS が背景知識に節だけでなく確定節論理を定義できることから、すでに学習したルールを背景知識に用いる。

## 2.2 ルール適用の利点

背景知識にルールを用いることの利点をまとめると以下のようである。

- 無駄な探索を避ける
- 精度の高いルールを導出する
- 階層的で、表現力の高いルールを導出する

しかし、あらかじめ背景知識をルールとして表現してしまうと、ルールに当てはまらなかったデータは考慮されなくなってしまうことから、精度の高い一般的なルールを導出できても、特殊なルールを導出できなくなってしまうという欠点をもつ。一方、複数のルールを同時に満たす事例の出現頻度が高くなり、ルールが導出し易くなると考えられる。

## 2.3 逐次学習

最も良いルールを繰り返し学習し、これを次の学習の際に背景知識として加える逐次学習は、学習ターゲット自身が学習ターゲットを説明する因子となり、階層的なルールの生成を可能にする手法である [1]。この手法も背景知識にルールを用いることで効率的に、表現力の高いルールを導出している。

## 3 緑内障診断ルールの学習




図 1: 眼底画像




図 2: 眼底図

## 3.1 診断の経験則

眼底画像 (図 1) による緑内障の診断は、(1) 網膜神経線維束欠損 (Nerve Fiber Layer Defect) と (2) 視神経乳頭陥凹の異常の観察による。神経線維の欠損は網膜上に緩いカーブを描いて現れ、乳頭陥凹の異常は辺縁幅の減少として現れる (図 2)。この二つの部分のどちらかが異常であれば緑内障であると診断されるし、一方の診断を行なうときに、他の一方の診断を参考にする。従って、診断ルールは双方の診断をお互いに参照し合う必要がある。そこで本研究では、(1),(2) の学習

\*Learning Diagnostic Rules for Glaucoma from Ocular Fundus Images

†Fumio Mizoguchi, Hayato Ohwada and Makiko Daidoji, Faculty of Sci. and Tech. Science University of Tokyo

‡Siroaki Sirato, Department of Ophthalmology, Faculty of Medicine, University of Tokyo, Tokyo

ターゲットそれぞれに対して得られたルールをお互いの背景知識として学習を行なう。

### 3.2 入力データ

39枚の眼底画像は、神経線維の欠損と陥凹の異常があるか診断がされている。データは医師の経験則にならって、眼底画像の診断に用いられる部分を乳頭から放射状に36分割(図3)していたのを、神経線維の流れに沿って26のセクターに分割(図4)して採取する。




図3: 36分割




図4: 26分割

分割された各セクターに対し、医師の診断を正事例とする。また、神経線維の欠損を説明する背景知識は画像のカラーの変化であるRGB濃度(red, green, blue)、陥凹の異常を説明する背景知識は乳頭辺縁(Rim)の幅に着目し、辺縁と乳頭半径の比(rd)と陥凹と乳頭半径の比(cd)とする。これらの述語表現と事例数は表1、表2の通りである。

正事例と負事例	事例数
nfld_abnormal(eye, sector)	146
\+ nflld_normal(eye, sector)	868
背景知識	事例数
red(eye, sector, real)	1014
green(eye, sector, real)	1014
blue(eye, sector, real)	1014

表1: (1) 神経線維束欠損

正事例と負事例	事例数
rim_abnormal(eye, sector)	238
\+ rim_normal(eye, sector)	776
背景知識	事例数
cd(eye, sector, real)	1014
rd(eye, sector, real)	1014

表2: (2) 視神経乳頭陥凹の異常

### 3.3 ルールの導出

学習ターゲット(1)、(2)に対し表1及び表2の背景知識を用いて学習を行なって得られたルールは、(1)に対しては6個、(2)に対しては15個であった。二つの学習ターゲットの相互関係を表すルールを導出するために、(1)のルールを(2)の背景知識に、逆に(2)のルールを(1)の背景知識に加えて学習を行なうと、例えば以下のようなルールが得られる。このルールは「あるセクターの神経線維が欠損していて、rd比が0.7以上0.73以下だったら、乳頭陥凹は異常である」という意味をもつ。

```
rim_anormal(A, B) :-
    nflld_abnormal(A, B),
    rd(A, B, C),
    C >= 0.7,
    C <= 0.7273.
```

また、背景知識にセクターの隣接関係のルールを加えると、

```
rim_anormal(A, B) :-
    nflld_abnormal(A, C),
    r_next(A, C, B),
    rd(A, B, D),
    D >= 0.6512, D <= 0.7679.
```

のようなルールが得られる。このルールは「右隣のセクターの網膜に異常があって、rd比が0.65以上0.77以下だったら、そのセクターの陥凹も異常である」という意味をもち、より表現力を増したルールであるといえる。

## 4 学習の精度

学習されたルールを背景知識に加えた場合と、学習していない基底事実を背景知識とした場合に、学習のパフォーマンスに差があるかをクロスバリデーション[3]を用いて実験した結果が表3である。

(1) 神経線維の欠損	Sensitivity	Accuracy	ルール数
ルール	72.6	52.2	14
基底事実	73.2	49.9	11
(2) 陥凹の異常	Sensitivity	Accuracy	ルール数
ルール	61.0	55.8	10
基底事実	63.9	55.4	8

表3: 学習パフォーマンスの比較

## 5 まとめ

結果から、背景知識にルールを用いた場合のほうが学習の精度が高いといえるが、学習にかかる時間は増化する。これはルールを満たす事例のほうが基底事実の事例数より多くなるために、探索に時間がかかるからである。また得られたルールは感度が高く、一般性が非常に低いので診断規則としては不十分である。背景知識にルールを用いることで表現力の高いルールを導出できることを示したが、精度は低いので、逐次学習を取り入れて精度を改善することが今後の課題である。

## 参考文献

- [1] 溝口, 大和田, 大導寺, 白土: Javaによる遠隔医療システムの開発(その1, その2), 情報処理学会第53回全国大会, 1996.
- [2] Mizoguchi F., Ohwada H., Constrained Relative Least General Generalization for Inducing Constraint Logic Programs, *New Generation Computing*, vol.13, 1995.
- [3] Weiss, S. M., Galen, R. S. and Tadepalli, P., Maximizing the Predictive Value of Production Rules, *Artificial Intelligence*, Vol. 45, 1990, pp. 47-71.