

山本研究室

(知能計算分野)

知-5

教授 山本 章博

研究室 : 総合研究7号館 324(教授室), 323, 325, 327

Web : <http://www.iip.ist.i.kyoto-u.ac.jp/>

Email : akihiro@i.kyoto-u.ac.jp

当研究室では、**機械学習理論**を中心にして人間の**高次推論機構**の性質を解明し、またそれを用いて、与えられたデータから適切な情報を取出すための**計算機構**や**ソフトウェア**を構築することを目指して研究を行っている。さらにこれらの研究を、**生命情報学**などにおけるデータ集合からの**知識発見**などへの応用し、**数理論理学**や**計算数学**との関係の解明へと展開している。

第2次AIブームの成果を第3次AIブームに生かす

研究の特徴

- 情報学基礎理論としての機械学習
 - 機械学習を基盤にし、論理や計算に立脚した新しい知的行為の基礎理論を求める
- 特に、データを読むための計算を対象にする。
 - プログラムを構築するには、構築のための“論理”が必要であるように、データを読むためにもそれ用の“論理”が必要
 - データ構造と代数的手法、数理論理学的手法特に“証明”を活用

機 械 学 習

人
文
科
学

生
命
情
報

言
語
処
理

ソ
フ
ト
ウ
ェ
ア

ア
ル
ゴ
リ
ズ
ム

数
理
論
理

情
報
理
論

統
計
学

数
学
代
数
解
析

こだわり所

第2次AIブーム: 数理論理を基盤

知識表現と証明

第3次AIブーム: ニューラルネットを基盤

大規模データからの機械学習

■ データ構造に着目した機械学習


- 木構造: ソースコードの構文解析木, HTMLのDOM-Tree
- 2部グラフ: トランザクション(商品と顧客)
- グラフ: 知識グラフ(Knowledge Graph)

■ 説明可能な機械学習

- 数学・数理論理は「推論の表現と正しさ」を数学的に保証
- 機械学習でも「推論の表現と正しさ」を数学的に保証することが重要
機械学習アルゴリズムの正しさとは何か？
 - ・深層学習が有効なのは, 学習の結果に説明を求められない場合


離散構造データからの機械学習

- 離散データを実数値ベクトルに変換して機械学習アルゴリズムを適用する手法も考えられる



離散構造データからの機械学習


- 離散データを実数値ベクトルに変換して機械学習アルゴリズムを適用する手法も考えられる



この関数の解釈は
少なくとも私には


“機械学習” そのものを一般化した枠組みを設定した上で
離散構造データ用の機械学習アルゴリズムを開発する。

● +1
● -1



Linear separation



構造データの出どころ



構文解析


形態素解析
(自然言語)

字句解析
(人工言語)




木構造と主成分分析の組み合わせ

主成分分析(PCA): 情報量の損失が少ない低次元空間を求める.



主成分分析




Tree PCA

■ 木構造から特徴的な構造を抽出



特徴構造としての主成分



構造データ間の距離

文字列 $s_0 = \text{abaaaab}$ と近いのはどっち？

$s_1 = \text{aababa}$ or $s_2 = \text{abaaaaaab}$

- “機械学習の教科書”にあるN-gramを使ってベクトル化

$$v_0 = \Phi(\text{abaaaab}) = (1, 1, 1, 0, 1, 0, 0, 0),$$

$$v_1 = \Phi(\text{aababa}) = (0, 2, 1, 0, 0, 1, 0, 0),$$

$$v_2 = \Phi(\text{abaaaaaab}) = (4, 1, 1, 0, 1, 0, 0, 0),$$


$$\|v_1 - v_0\|^2 = 4 < \|v_2 - v_0\|^2 = 7$$

- 構造体特有の距離である編集距離を用いると

$$d(s_0, s_1) = 4 > d(s_0, s_2) = 3$$

木構造データ間の距離と直交性

- 木構造データ間の編集距離



- 木構造は2次元的に広がるため、バリエーションが多い
- 木構造間の直交性: H30年度卒論で厳密に定式化

木構造間編集距離の計算量

	編集距離算出		局所構造算出	
	Tai マッピング	制約 マッピング	Tai マッピング	制約 マッピング
順序木	$O(n^3)$ [Demine 06]	$O(n^2)$ [Zhang 95]	$O(n^4)$ [Ouagraoua et al. 07]	$O(n^2 d \log d)$
無順序木	MAXSNP 困難	$O(n^2 d \log d)$ [Zhang 96]	MAXSNP 困難	$O(n^2 d \log d)$ [Ferraro et al. 05]
前順序木	MAXSNP 困難	$O(n^2 d \log d)$ [Ouagraoua et al. 09]	MAXSNP 困難	$O(n^2 d \log d)$


n : ノード数 d : 最大次数

※ 国際会議 GABA2014@横浜で発表

IPソルバを用いた木構造間距離の高速計算

- 近年では高速な汎用ソルバ(SAT/IPなど)が利用可能
→ 高速なソルバをターゲットとする”コンパイラ”を開発


Input



IP Problem

Maximize: $\sum m_{i,j} - 2o_{|Ti|, |Ti+1|}$
Subject to:
 $o_{1,1} \leq o_{1,2}, \quad o_{1,1} \leq o_{2,1}, \quad \dots$

Output



IP Solution

$m_{1,1} = 1,$
 $m_{1,2} = 0, \dots$

IP Solver

IP = LP + integer restriction

□ Complexity is NP-hard


□ But efficient solvers exist

さらに高速なIP定式化


- 動的計画法を用いることで, コンパクトなIP定式化に成功

	編集距離		断片距離	
	既存手法	提案手法	既存手法	提案手法
部分問題数	1	n^2	1	1
制約式数	$O(n^4)$	$O(n)$	$O(n^4)$	$O(n)$

編集距離



断片距離



※ 国際会議COCOA2017@上海で発表

アラインメント距離のIP定式化

- アラインメント距離のIP定式化に成功
 - アラインメント距離: 編集距離の変種

	既存手法	提案手法
方法	動的計画法 計算量: $O(6^d n^2)$	IP 制約式数: $O(n^4)$
d が小さい	速い	遅い
d が大きい	遅い	速い

実行時間


n	d	既存手法	提案手法
15-19	0-3	1ms以下	728ms
	8-11	7165ms	374ms

n: ノード数 d: 最大次数

※ 第106回人工知能基本問題研究会@指宿で発表

数理最適化を用いた言語モデルの頑健性検証

- 最小単語置換の敵対的サンプルを求める問題を整数線形計画問題として定式化



最小单語置換問題

$$R = \min_{\epsilon \in \mathcal{D}} |\epsilon|$$

subject to $f(x + \epsilon) \neq y$

x : 入力テキスト e : 単語置換パターン
 y : 正解ラベル f : NNモデル
 $|\epsilon|$: 単語置換パターン ϵ の単語置換数

どの程度誤差を加えると間違えてしまうのかを評価

整数線形計画問題(提案法)の解は必ず最適解(最小の単語置換)

新聞記事からイベントの発生時期を特定

- 新聞記事におけるイベントと発生時期の文構造に着目
- 典型的な文構造:T-R-E, E-R-Tを抽出し, 時期を特定

T:Time (“今日”, “3月11日”)


R:Relation (“の”, “が起きた”)

E:Event (“火災”, “東日本大震災”)

イベントと時間の関係を抽出

Target: 東日本大震災

Event Relation Time



記事

東日本大震災が起きた2011年3月から……


平成23年3月11日に、東日本大震災で私は……

B氏は2011年3月の東日本大震災発生後……


発生時期: 2011年3月11日

知識グラフから四択問題の自動生成

- 知識グラフから二部グラフに着目して抽出することで、選択肢と解答根拠を自動生成
- 正答語句を入力すると、問題の選択肢と解答根拠が得られる



根拠



選択肢

<問題文>

A,B,C,Dは共に古代ギリシャの倫理学者である
A,BはBC5世紀の人物である
A,C,Dは死の哲学者でもある
Aの父親がAriston of Athensである時、
Aに入るものを以下の1~4のうちから一つ選べ


1. **Plato** 2. Socrates 3. Pythagoras 4. Epicurus



問題作成者

NNによるソースコード要約(修士)

- Tree-LSTMを理論的整備してソースコード要約へ応用



Source code	<pre>public boolean more() throws JSONException { next(); if (end()) { return false; } back(); return true; }</pre>
Gold	Determine if the source string still contains characters that next() can consume
Generated	Determine if the source string still contains characters that next() can consume
Source code	<pre>@JsonIgnore public boolean isDeleted(){ return state.equals(Experiment.State.DELETED); }</pre>
Gold	Signals if this experiment is deleted
Generated	Returns true if this session has been deleted

Tree-LSTMを利用した情報統合

- 自然言語データに対する深層学習モデルであるLSTMをベースに木構造向けモデルを設計
- 同一目的だがサイトによって表現形式が異なる情報の統合に応用
 - 大学のシラバスなど
京都大学のシラバスサイト

The diagram illustrates the process of integrating syllabus information from two different university websites into a single, unified table. On the left, two screenshots of university syllabus pages are shown: the top one is from Kyoto University's 'KYOTO U OPENCOURSEWARE' site, and the bottom one is from Tokyo University's syllabus page. A blue arrow points from these two sources towards a table on the right, which represents the integrated information.


科目名	単位数	担当教員	曜時限
数学入門	2	山田	火1
英語	4	鈴木	水3
統計 I	2	佐藤	木4
方言学	2	田中	月2
グラフ理論	2	平山	水6
データ分析	1	井上	金1

東京大学のシラバスサイト

※第115回人工知能基本問題研究会で発表

ソースコード・クローンの検出

コードをトークンのN-gramで多重集合化 + CCFinderの正規化



※日立-京大ラボとの共同研究

※第199回ソフトウェア工学会@帯広で発表

※情報処理学会CS領域奨励賞受賞

定理自動証明の新しい側面

- 第2次AIブームの基盤であった定理自動証明を現代の視点から再考察する

可換マッチング問題

- $f(t_1, t_2) = f(t_2, t_1)$ とみなす(可換)

Input

s: 項

t: 変数を含まない項

Output

s を t に等しくするような変数への代入
は存在するか？

Example

s = $f(x, a)$

t = $f(a, b)$

代入 x/b



$f(b, a)$



答え
Yes

5

Akutsu+の予想: sとtを等しくするような代入の個数は高々 2^{k-1} 個
に対して, 1つの場合を除いて成立することを証明した

※第112回(予稿)第113回(口頭)人工知能基本問題研究会で発表

BDDを用いたILPの解の列挙

ILP問題

$$\mathcal{E}^+ = \{e(0), e(s^2(0))\}$$

$$\mathcal{E}^- = \{e(s(0))\}$$

$$\mathcal{B} = \{\}$$

$$\Sigma \cup \mathcal{B} \models \mathcal{E}^+$$

$$\Sigma \cup \mathcal{B} \not\models \mathcal{E}^-$$

大量に生成される仮説


$$\Sigma = \{e(0), e(s^2(0))\}$$

$$\Sigma = \{e(0), e(s^2(x)) \leftarrow e(x)\}$$

$\vdots$

命題変数を生成




BDDで圧縮表現



- 帰納論理プログラミング(ILP)
一階述語論理の技法で分類問題を解決
- 二分決定グラフ(BDD)
ブール関数をコンパクトに表現

旅行者移動データからの頻出経路発見


- 外国からの旅行者の移動記録データに対して、**位置情報を住所表記に変換した上で**、頻出**記号列**発見手法を適用し、旅行者のクラスと経路のクラスの対応関係を**閉集合**として抽出することに成功



※国立情報学研究所, (株)ノースグリッドとの共同研究
※国際会議 DS 2020@ギリシャで発表

知識グラフ上の推論の精緻化

- 知識グラフ(knowledge graph): 劇的に発展した自然言語処理技術を用いて(大量の)自然言語データから構築された**知識ベース**




歓迎

- システム構築, 基礎理論いずれに興味があっても歓迎
 - 議論を通じて自ら追究する
 - 簡単な事柄でも, 動的計画法などの数学的手法に抵抗がない
 - 理論だけでなく実装による成果の確認を行える
 - 実装の数学的に意味を自分の言葉で説明する

研究室の環境

- 学生全員がMacbook/Mac Pro使用できます！
 - Windows/Linuxも使えます！
 - 欲しい本やデバイスなども！
- (他の研究室と比べていませんが)机広いです！



質問や相談があればメールで

教授: 山本章博 akihiro@i.kyoto-u.ac.jp

※ メールで質問の際は件名を「大学院志望」とし、氏名を忘れずに！