

# 機械学習の活用に向けて

統計数理研究所

松井知子

# 機械学習

- データから知識を抽出する方法論～データからの帰納
- McKinsey Global Instituteのレポート(2011)
  - 機械学習の重要性を言及  
「機械学習はイノベーションの次の大きな波を呼ぶ」
- P. Domingos, “A few useful things to know about machine learning,” Comm. of The ACM, 55(10), 2012
  - 機械学習の活用に必要な知識を紹介

# 機械学習


- Learning = Representation + Evaluation + Optimization  
[Domingos, 2012]

- 機械学習 ~

コーディング + モデリング + 目的関数 + 最適化

Representation  
アプリケーションドメイン  
の専門家

機械学習の専門家



# 機械学習

- モデリング
  - 線形回帰/識別モデル、ニューラルネットワーク、SVM、ロジスティック回帰、グラフィカルモデル、混合ガウス分布、隠れマルコフモデル、決定木 など
- 目的関数
  - 最小二乗誤差、最小KLダイバージェンス、最大マージン、最尤、最大事後確率 など
- 最適化
  - 連続最適化: 最急降下法、共役勾配法、ニュートン法、EMアルゴリズム など
  - 離散最適化: ビーム探索、greedy探索 など

# 機械学習

- David Hume (1711-1776、哲学者)

「知識の起源を知覚により得られる観念にあるとすれば、  
確実な知に人間本性が達することは原理的に保証されない」

→何らかの知識や仮定の必要性

- No-free-lunch定理 [Wolpert and Macready、1995]

「どの学習機械に対しても、ランダム推測の方が・優れている  
目的関数か・少なくとも一つ存在する」

# ITSのデータ

- プローブ情報、カーナビ情報、車両情報、持ち込み端末のセンサ情報など
- ビッグデータの三つの「V」
  - Volume (膨大なデータ)
  - Velocity (高速度でのデータ入出力)
  - Variety (多種多様なデータ)

カーネル法

# カーネル法

- カーネル関数(データ同士の類似の度合いをはかる関数)を利用して識別や回帰の問題に対処する。
  - データを高次元空間に写像した上で処理する。

## カーネル関数〜次元の呪いの克服

- カーネル関数は多種多様なデータに対して設計できる。
  - 連続値／離散値
  - ベクトル、系列、グラフ、木、...
- カーネル法の例
  - サポートベクターマシン、カーネルロジスティック回帰マシン、ニューラルネット、カーネルPCAなど

花塚泰史 ((株)ブリヂストン/総研大)、樋口知之、松井知子(統数研)

2012 IET International Conference on Information Science and  
Control Engineering (ICISCE 2012)

# DEVELOPMENT OF THE ROAD-SURFACE CONDITION CLASSIFICATION SYSTEM



# カーネル法による路面状態の判別


- 入力: タイヤ振動の時系列信号  
(ケプストラムベクトル時系列)
- 出力: 路面状態 (ドライ / ウェット / 圧雪 / 凍結)
- 判別法:
  - サポートベクターマシン (SVM) + グローバルアライメント (GA) カーネル
  - 隠れマルコフモデル (HMM)

# GAカーネル

[Cuturi, Vert, Birkenes and Matsui, ICASSP2007]

- 可変長、観測値のばらつきを考慮
- 全パス  $\pi$  に沿って累積距離を計算

$$S(\pi) = \sum_{i=1}^{|\pi|} \phi(x_{\pi_1(i)}, y_{\pi_2(i)}) \quad \phi(x, y) = -\|x - y\|^2$$



# GAカーネル

- 定義: 
$$K_{GA}(\mathbf{x}, \mathbf{y}) = \sum_{\pi \in A(\mathbf{x}, \mathbf{y})} \exp(S(\pi))$$
$$= \sum_{\pi \in A(\mathbf{x}, \mathbf{y})} \exp\left(\sum_{i=1}^{|\pi|} \phi(x_{\pi_1(i)}, y_{\pi_2(i)})\right)$$
$$= \sum_{\pi \in A(\mathbf{x}, \mathbf{y})} \prod_{i=1}^{|\pi|} k(x_{\pi_1(i)}, y_{\pi_2(i)}) \quad [k = e^\phi]$$

# 実験

- 実験条件

- 利用したタイヤ: 4種類(うち1種類を学習、残り3種類をテスト)
- コーディング: 8次元ケプストラム +  $\Delta$  +  $\Delta \Delta$  ~ 24次元ベクトル  
(窓長3ms、フレームシフト2ms)

- 結果

- GAカーネルによる方法: 97.2%
- HMMによる方法(4状態): 85.1%

# まとめ

- 機械学習はITSを含め、ビッグデータ解析の重要なツール：
  - うまく活用するためには、対象ドメイン／アプリケーションに即した知識や仮定が必要
  - データの多様性に対応できる方法、カーネル法を紹介
  - 「カーネル法による路面状態の判別」の研究例を紹介