機械学習工学の必要性と現状

丸山宏[†1]

概要：深層学習を始めとする（統計的）機械学習の技術が成熟してきた．機械学習を使ったシステム開発は今までのソフトウェア開発と異なる部分があり，必ずしも既存のソフトウェア工学を適用してうまく行くものでもない．機械学習が広くシステム開発の一部に使われるようになるには，機械学習の特性に合わせた方法論が必要である．これを我々は機械学習工学と呼び，ソフトウェア工学と機械学習の接点として広く知見を集め，体系化したいと考えている．本稿は機械学習工学の主要な課題を述べ，機械学習工学の現状を俯瞰し，今後の展望を考える．

キーワード：機械学習，ソフトウェア工学，深層学習，再利用，品質，要求工学

Machine Learning Engineering: Necessity and Status

Hiroshi Maruyama[†1]

Abstract: Statistical machine learning such as deep learning is becoming matured and ready for real-world applications. Developing machine learning-based systems differs from developing conventional systems and sometimes the best practices of current software engineering may not apply. We need a new practice, called Machine Learning Engineering, that is a body of knowledge for developing machine learning-based systems. This manuscript presents main issues in machine learning engineering and discusses the future activities in the field.

Keywords: Machine Learning, Software Engineering, Deep Learning, Software Reuse, Software Quality, Requirement Engineering

1. はじめに

機械学習あるいは深層学習は，訓練データセットからシステムを帰納的に生成する汎用のプログラミング手法と見ることができる．プログラミング言語に相当する深層学習フレームワークなどが整備されるようになって，機械学習を一般のシステム開発に利用する機運が高まってきた．しかし，顧客要件をモデル化し，それを段階的に詳細化していく従来の演繹的システム開発と違って，機械学習を利用したシステム（本稿では**機械学習応用システム**と呼ぶ）の開発では，顧客要件を訓練データの形で表現し，その後は学習によって（半）自動的にシステムが作られる．このような帰納的なシステム開発における方法論を我々は**機械学習工学**と呼び，その知識の体系化を目指している[1]．本稿では，機械学習工学の主要な課題を述べ，機械学習工学の現状を俯瞰し，今後の展望を考える．

2. 機械学習工学の主要な課題

通常，機械学習応用システムは図 1 に示すように，訓練のパイプラインと推論のパイプラインからなる．訓練においては，生データを前処理し，必要に応じて正解データ（教師信号）を付与し，それを訓練データとして学習アルゴリズムに与え，訓練済みモデルを生成する．推論においては，同様の前処理を施し，訓練済みモデルを利用して推論を行う．

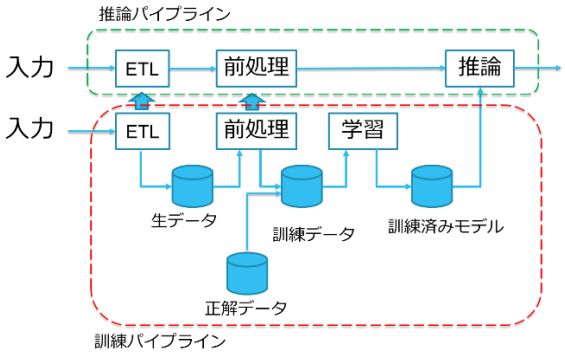

図 1　機械学習応用システムのパイプライン

以下，この図の様々なバリエーションを考えながら機械学習工学の課題を考える．

2.1 訓練データの与え方

訓練データの与え方には，利用シーンによって以下のような様々なパターンがあり得る．

- 人手で正解データを与える（**アノテーション**と呼ばれる）
- 他のシステムから（半）自動的に正解データを得る（例えば予測問題では，多くの場合時間が経てば正解が得られる）．
- 多くの正解無しデータに，少量の正解つきデータを加えて訓練する．
- 正解無しデータのみで訓練を行い，生成モデルをとして利用する．

†1 Preferred Networks, Inc.

©2018 Information Processing Society of Japan

- 強化学習においては，対象システム（シミュレータ）を実際に制御してその出力を教師信号として用いる．

どのような問題設定に対してどのような訓練データを用意するかは機械学習応用システムの成功・失敗を左右する重要な決定であり，ベスト・プラクティスの整備が求められる．

2.2 生成物の再利用

生データ，訓練データ，訓練済みモデル，またそれらを処理するプログラムなど，図 1 に示した様々な生成物は，再利用の対象となる．特に，人手でアノテーションされた訓練データ，そこから大量の計算資源とノウハウを投入して作られた訓練済みモデルは価値の高い生成物であり，出来る限り再利用されることが望ましい．

訓練済みモデルについては，以下のような再利用パターンがある．

- **単純な複製**. 同じモデルをそのまま同じタスクに利用する．
- **ファインチューニング**. 少量の新たな訓練データを加えることによって，異なるタスクに適用する．
- **アンサンブル**. 同じタスクに対する複数のモデルを並列に走らせ，それらの平均を取ることによって精度を向上させる．
- **蒸留**. 元の学習済みモデルに対して繰り返し推論を行わせることで，新たな訓練データを生成し，同じタスクだがまったく別の訓練済みモデルを生成する．

生成物の再利用については議論がはじまったばかりであり，今後の議論の深まりが期待される．

2.3 品質の担保

深層学習を使ったシステムでは，図 1 のどの部分のどの変更も，他のすべての部分に影響を与える CACE(Change Anything Changes Everything)と呼ばれる性質を持つ[2]．このため品質の担保が難しい．品質に関しては，以下のような課題が知られている．

- ユニットテスト. 現在多くの機械学習応用システムにおいてテストは，各コンポーネントがそれぞれ正しく動いているかは，検証が難しいため，実際に推論を行ってその精度を見ることによって行われている．
- 回帰テスト．機械学習応用システムにおいては，たとえ全体の精度が上がったとしても，過去にたまたま正解となっていた入力に対して，新しい訓練済みモデルが常に正しい出力を出すとは限らない．
- コーナーケース. 機械学習に於いての評価用データは通常，訓練データと同じ分布からランダムサンプリングしたものが用いられるが，それらは必ずしもプログラムのバグを見つけるのに最適ではない．
- 新しいタイプの攻撃. 機械学習応用システムに対しては，訓練データに意図的に汚いデータを紛れ込ませることにより，結果を誤らせるという攻撃がありうる．
- 説明性．特に深層学習においては，結果の説明性が問題とされている．

これらの課題があるにも関わらず，機械学習応用システムにおいては，品質をプロセス指標ではなくプロダクト指標で評価できる可能性がある．そのためには，出来上がったシステムを，開発者に開示されない評価用データによって第三者が評価する仕組みを整える必要がある．

2.4 要求工学

- 顧客の理解. 機械学習はあくまでも帰納的にプログラミングを行う技術であり，これを［人工知能］としての擬人的な知能を期待してはならない．また，システム開発は多分に探索的であるので，どの段階で実運用に踏み切るかの明確な判断基準を顧客が持っている必要がある．
- 要求の厳密化．強化学習など，機械学習を最適化に使う場合，効用関数は顧客の要求を厳密に反映したものでなければならない．機械学習は与えられた効用関数を最大化する解を探すので，その解が常識に照らして受け入れられないものが出てくる可能性があることに注意しなければならない．

2.5 演繹的プログラミングとの組み合わせ

システム全体をエンドツーエンドで機械学習で作る方法もあるが，多くの場合、機械学習と通常の演繹的なプログラミングとが混合したものになると考えられる．どのような場合にどのようなアーキテクチャ・パターンになるのか，整理していく必要がある．

3. 機械学習工学の現状

ニューラルネットワークの国際会議 NIPS では，2014 年の機械学習工学ワークショップなど，不定期に関連する議論が行われている．国内では，国立情報学研究所の石川冬樹准教授らを中心として，機械学習工学の確立を目指す動きが加速している．日本ソフトウェア科学会に新たに研究会を立ち上げようとしている．

4. 将来展望

今後の情報技術において，機械学習に基づく帰納的プログラミングは，今までの演繹的プログラミングと並ぶ基幹的な技術になるであろう．

機械学習の実応用では，多くの知見が産業界で蓄積されつつある．これらの知見をうまく体系化するとともに，そこで同定される課題をアカデミアが解いていくというよいコラボレーションが花開いていくことを期待したい．

参考文献

[1]丸山宏，機械学習工学に向けて，日本ソフトウェア科学会第 34 回大会(2017 年度) 講演論文集.

[2]Sculley, D., Phillips, T., Ebner, D., Chaudhary, V., and Young, M.: Machine learning: The high-interest credit card of technical debt, (2014).

©2018 Information Processing Society of Japan