

# 最適学習モデル構築技術を搭載したAI特許自動分類ツール(PatentNoiseFilter)

AI patent automatic classification tool equipped with optimal learning model construction technology “PatentNoiseFilter”.

IRD 国際特許事務所 所長・弁理士／株式会社アイ・アール・ディー

## 谷川 英和

1986年神戸大学工学部システム工学科卒業。同年、松下電器産業(株)[現パナソニック]に入社し、中央研究所等において、データベース管理システム等の研究開発に従事。1997年同社知的財産権部門に異動。1999年弁理士試験合格。2002年1月、IRD国際特許事務所を開設。所長、弁理士。2003～2007年3月京都大学COE 研究員、2007年4月～京都大学非常勤講師、2011年4月～大阪大学非常勤講師(現招聘教授)2019年4月～関西学院大学非常勤講師、博士(情報学)。弁理士会、日本知財学会、情報処理学会各会員。2007年度から特許版産業日本語委員会委員。

中央大学理工学部ビジネスデータサイエンス学科教授

## 難波 英嗣

2001年北陸先端科学技術大学院大学情報科学研究科博士後期課程修了。博士(情報科学)。東京工業大学精密工学研究所助手、広島市立大学大学院情報科学研究科准教授等を経て、2019年より中央大学理工学部教授。自然言語処理、テキストマイニングの研究に従事。

### 1 はじめに

AI技術のうちの中心的な技術である機械学習を用いて、特許を自動的に分類するツールが、多数、開発されている。

一般的な特許自動分類ツールは、特許のリストのユーザによる分類結果である教師データをAIに学習させ、学習モデル(学習器等と言っても良い)を構築する学習モジュール(図1参照)と、学習モデルを用いて特許データの分類予測を出力する予測モジュール(図2参照)とを有する。

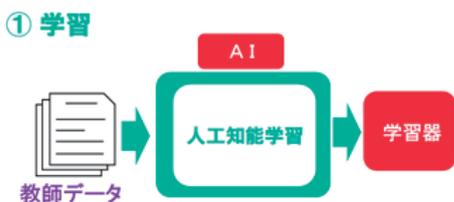


図1 学習モジュールの概念図



図2 予測モジュールの概念図

しかし、一般的な特許自動分類ツールには、以下の4つの課題がある。

#### (1) 自動分類の精度が分からない

教師データの数が不足しているため、分類に与える特許データが不適切であるため、アルゴリズムが分類対象の特許データとミスマッチであるため等の原因により、精度の高い学習モデルが構築できていない場合も多い。

一方、ユーザは、特許自動分類ツールの学習処理により構築された学習モデルの精度が分からずに、学習モデルを使用せざるを得ない場合が多く、特許自動分類ツールの使用が促進されていない原因となっている。

## (2) 特許分類の局面により重視する指標が異なる

特許分類が必要な局面として、研究プロジェクトの発足時の大規模特許調査、製品開発の開始時の大規模特許調査、特許出願前の先行特許調査、SDI 特許調査、他社特許権を無効にするための先行特許調査等の種々の局面がある。

そして、特許分類の局面により、「再現率」を上げたい場合、「適合率」を上げたい場合、「F 値」を上げたい場合、「正解率」を上げたい場合等、上げたい指標が異なる。なお、再現率とは「検索された正しい特許数／本来検索されるべき全ての特許数」であり、見逃さない確率である、と言える。また、適合率とは「検索された正しい特許数／検索された特許数」であり、誤検出ししない確率である、と言える。また、F 値は「(再現率+適合率)／2」である。

## (3) 分類対象の特許データにより使用すべきアルゴリズムやモジュールが異なる

特許分類に利用可能な機械学習には、深層学習、ランダムフォレスト、決定木、サポートベクターマシン(SVM)等の複数のアルゴリズムがあり、各アルゴリズムにおいて、いくつかのモジュールが開発されている。

一方、既存の特許自動分類ツールの多くは、固定の一つのモジュールを用いており、精度の高い学習モデルが構成される場合もあるが、精度が上がらない学習モデルが構成される場合もある、と考えられる。

## (4) 分類対象の特許により使用すべき特許データが異なる

一つの特許データには、特許請求の範囲、明細書、要約書、特許分類コード(例えば、IPC、FI、Fターム)等が含まれる。これらの特許データのうち、どれを使用すれば、精度の高い特許自動分類が可能な学習モデルが構築できるかをユーザが判断することは極めて困難である。

一方、既存の特許自動分類ツールにおいて、ユーザが与えた特許データのうち特許自動分類ツールが予定している特許データを固定的に使用する、またはユーザが与えた特許データをすべて使用して学習モデルを構築することが一般的である。

以上の4つの課題により、特許自動分類ツールの利

用が限定的になっている、と考える。

## 2 最適学習モデル構築技術の概要

ユーザが安心して、精度の高い特許自動分類を行うために、最適学習モデル構築技術を開発した。

最適学習モデル構築技術の特徴は、以下の(1)から(3)の3点である。

### (1) ユーザ指定の指標の評価値を最大にする学習モデル

第一は、再現率、適合率、F 値、正解率の4つの指標のうち、ユーザが指定した指標の値を測定し、その値が最大となる学習モデルが自動構築できる点である。

### (2) 複数の各モジュールと複数パターン異なる各特許データとの多数の組を用いた学習モデルの評価

第二は、複数の各アルゴリズムに対応する複数の各モジュールに、種々の組み合わせの特許データを与え、モジュールと特許データとの組を、多数、構成し、組ごとに、ユーザから指定された指標における学習モデルの精度を測定する点である<sup>1)</sup>。その結果、ユーザから指定された指標の値が最大となるモジュールと特許データとを用いた学習モデルが自動構築できる。

### (3) 複数の各モジュールと複数パターン異なる各特許データとの組ごとの論理演算結果の評価

第三は、使用する特許データのパターンごとに、複数のモジュールの予測結果の論理演算(AND、OR、多数決)の結果についても、ユーザから指定された指標における学習モデルの精度を測定する点である。その結果、複数のモジュールの予測結果の論理演算の結果も含めて、ユーザから指定された指標の値が最大となるモジュールと特許データとを用いた学習モデルが自動構築できる。

### (4) 最適学習モデル構築技術の成果物

最適学習モデル構築技術において、以上の第一から第三の点を実行し、ユーザから指定された指標の値が最大となるモジュールと特許データとの組または論理演算を

決定し、当該情報（学習モデル仕様情報と言う）と対に、最適学習モデルを蓄積する。

なお、学習モデル仕様情報とは、ユーザが重視する指標の値を最大にする学習モデルの仕様であり、予測処理に使用するモジュールおよび特許データを特定する情報である。

予測処理において、学習モデルと対に格納されている学習モデル仕様情報を用いて、使用する特許データと使用するモジュールが決定され、決定した特許データとモジュールと学習モデルとを用いて、特許を分類する。

### 3 PatentNoiseFilter<sup>®</sup> (PNF)の概要

PNFは、他の特許自動分類ツールと同様、学習処理、および予測処理を行う。

#### (1) 学習処理

最適学習モデル構築技術を搭載したPNFの学習処理の概要について説明する。

PNFは、BERT (Bidirectional Encoder Representations from Transformers)<sup>2)</sup>を含む3種類のディープラーニング系のモジュールとランダムフォレストのモジュールとの合計4つの機械学習の学習モジュールと予測モジュールとを備えている。なお、BERTについて、コアモジュールの制約から二値分類にしか対応していない。一方、他の3つのモジュールは、多値分類にも対応している。

PNFにおいて、ユーザは、学習モデルの構築のために、手順1から手順3で、教師データをアップロードし、学習モデルのファイル名を入力する。なお、教師データは、人手により特許データを分類したCSVファイルである。

そして、図3に示すように、手順4で、ユーザは、4つのうちのいずれかのモジュールまたは「自動選択」のうちのいずれかを選択する。

そして、手順4で「自動選択」が選択された場合、ユーザは、手順5で学習処理および予測処理に使用する情報を選択する。なお、使用する情報として、ユーザは、「要約書+分類コード」「要約書+特許請求の範囲+分類コード」「要約書+解決手段効果表現文+分類コード」「要約書+特許請求の範囲+解決手段効果表現文+分類コー

ド」または「おまかせ」が選択できる。なお、「おまかせ」を選択した場合、「要約書+分類コード」「要約書+特許請求の範囲+分類コード」を採用する。また、ユーザは、「要約書+分類コード」「要約書+特許請求の範囲+分類コード」「要約書+解決手段効果表現文+分類コード」「要約書+特許請求の範囲+解決手段効果表現文+分類コード」のすべてを選択しても良い。

なお、解決手段効果表現文とは、明細書から抽出した文であり、解決手段と効果の両方が現れた文である<sup>3) 4)</sup>。解決手段効果表現文は、例えば、「〇〇手段により、～できる。」といった文であり、特許分類にとって重要であると考えられる文である。ただし、明細書から解決手段効果表現文を抽出する処理は多大な処理コストがかかるため、「おまかせ」を選択した場合は、解決手段効果表現文の抽出処理を行わないこととした。

次に、手順6で、ユーザは、「再現率」「適合率」「F値」「精度（正解率）」から、ユーザが重視する一つの評価指標を選択する。

手順4から手順6における操作の完了後、ユーザが「学習」ボタンを指示した場合、学習処理が行われ、最適学習モデルが構成される。

手順4. アルゴリズムの選択  
学習アルゴリズムを選択してください。

- ディープラーニング 1
- ランダムフォレスト
- ディープラーニング 2
- BERT
- 自動選択

手順5. 使用する情報の選択

- 要約書+分類コード
- 要約書+特許請求の範囲+分類コード
- 要約書+解決手段効果表現文+分類コード
- 要約書+特許請求の範囲+解決手段効果表現文+分類コード
- おまかせ

手順6. 重視する評価指標を選択

- 再現率
- 適合率
- F値
- 精度

学習

図3 PNFの学習処理の操作画面

#### (2) 予測処理

予測処理の手順1において、ユーザは、学習モデルの一覧から使用する学習モデルを選択する（図4）。



図4 PNFの予測処理の操作画面(1)

図5に示すように、手順2において、ユーザは、予測対象のファイルを選択する。予測対象のファイルとは、PNFにより自動分類する対象の特許データが含まれる特許リストのCSVファイルである。

また、手順3において、ユーザは、予測処理を行った結果を蓄積するファイル名を指定する。

手順1から手順3の入力の後、ユーザは、「予測」ボタンを指示することにより、予測処理が行われ、特許が自動分類された結果のCSVファイルが出力される。



図5 PNFの予測処理の操作画面(2)

## 4 PNFの処理結果

### (1) 学習処理の処理結果

図6は、PNFの学習処理の処理結果の第一の出力例である。図6は、二値(「1」または「-1」)のうちのいずれかに分類された特許データのリストである教師データを用いて学習処理を行った場合の出力例である。PNFでは、4つのアルゴリズムと種々の情報(要約書、特許請求の範囲、分類コード、重要情報等)と統計処理の有無との多数の組み合わせを構成し、各組み合わせごとに各指標の値を算出し、提示できる。

また、図6において、ユーザが選択した指標である「F値」について、「要約書+分類コード」を用いた場合の「4つのアルゴリズムの多数決」が最良の結果「0.809」であり、「要約書+特許請求の範囲+分類コード」を用いた場合の「4つのアルゴリズムのAND」が最悪の結果「0.661」であったことを示す。

また、図6において、正解率(精度)は、「0.83」～「0.71」までの幅があり、適合率は「0.903」～「0.647」までの幅あり、再現率は「0.977」～「0.523」までの幅があったことを示す。

アルゴリズム	使用する情報	Average accuracy (精度)	Average precision (適合率)	Average recall (再現率)	Average F1 score (F値)
アルゴリズム2 (ランダムフォレスト)	要約書, 分類コード	0.809	0.778	0.841	0.806
アルゴリズム1 (ディープラーニング1)	要約書, 分類コード	0.802	0.776	0.816	0.793
アルゴリズム3 (ディープラーニング2)	要約書, 分類コード	0.71	0.683	0.706	0.693
アルゴリズム4 (BERT)	要約書, 分類コード	0.812	0.804	0.795	0.799
4つのアルゴリズムの多数決	要約書, 分類コード	0.812	0.78	0.841	0.807
4つのアルゴリズムのAND	要約書, 分類コード	0.748	0.903	0.523	0.661
4つのアルゴリズムのOR	要約書, 分類コード	0.738	0.647	0.977	0.778
アルゴリズム2 (ランダムフォレスト)	要約書, 特許請求の範囲, 分類コード	0.802	0.779	0.81	0.792
アルゴリズム1 (ディープラーニング1)	要約書, 特許請求の範囲, 分類コード	0.748	0.729	0.749	0.736
アルゴリズム3 (ディープラーニング2)	要約書, 特許請求の範囲, 分類コード	0.787	0.802	0.742	0.766
アルゴリズム4 (BERT)	要約書, 特許請求の範囲, 分類コード	0.83	0.855	0.772	0.809
4つのアルゴリズムの多数決	要約書, 特許請求の範囲, 分類コード	0.805	0.793	0.802	0.794
4つのアルゴリズムのAND	要約書, 特許請求の範囲, 分類コード	0.766	0.903	0.567	0.691
4つのアルゴリズムのOR	要約書, 特許請求の範囲, 分類コード	0.78	0.703	0.925	0.798

図6 PNFの学習処理の第一の処理結果の一部

また、図7は、PNFの学習処理の処理結果の第二の出力例である。図6は、A,B,Cの3つのうちのいずれかに分類された特許データのリストである教師データを用いて学習処理を行った場合の出力例である。多値分類の場合、PNFでは、BERTを除く3つのアルゴリズムと種々の情報(要約書、特許請求の範囲、分類コード、重要情報等)と統計処理の有無との多数の組み合わせを構成し、各組み合わせごとに各指標の値を算出し、提示できる。

図7においても、使用するモジュール、使用する特許データにより正解率(精度)およびF値が異なる。

つまり、図6、図7に示す通り、使用するモジュール、使用する特許データにより各指標の精度にかなりのばらつきがある。このことは、使用するモジュールや使用する特許データ等の多数の組み合わせを用いて学習モデル

を構築してみて、評価した結果、最も精度の高いものを最適学習モデルとして自動選択する最適学習モデル構築技術が極めて有用であることを示している、と言える。

アルゴリズム	使用する情報	Average overall accuracy (精度)	Average macro F1 score (F値)
アルゴリズム2 (ランダムフォレスト)	要約用, 分類コード	0.99	0.991
アルゴリズム1 (ディープラーニング1)	要約用, 分類コード	0.989	0.99
アルゴリズム3 (ディープラーニング2)	要約用, 分類コード	0.972	0.972
4つのアルゴリズムの多数決	要約用, 分類コード	0.995	0.995
アルゴリズム2 (ランダムフォレスト)	要約用, 特許請求の範囲, 分類コード	0.986	0.987
アルゴリズム1 (ディープラーニング1)	要約用, 特許請求の範囲, 分類コード	0.981	0.983
アルゴリズム3 (ディープラーニング2)	要約用, 特許請求の範囲, 分類コード	0.962	0.964
4つのアルゴリズムの多数決	要約用, 特許請求の範囲, 分類コード	0.988	0.989
アルゴリズム2 (ランダムフォレスト)	要約用, 特許請求の範囲, 分類コード, 解決手段効果表本文	0.991	0.992
アルゴリズム1 (ディープラーニング1)	要約用, 特許請求の範囲, 分類コード, 解決手段効果表本文	0.979	0.979
アルゴリズム3 (ディープラーニング2)	要約用, 特許請求の範囲, 分類コード, 解決手段効果表本文	0.957	0.959
4つのアルゴリズムの多数決	要約用, 特許請求の範囲, 分類コード, 解決手段効果表本文	0.989	0.99
アルゴリズム2 (ランダムフォレスト)	要約用, 分類コード, 解決手段効果表本文	0.989	0.99
アルゴリズム1 (ディープラーニング1)	要約用, 分類コード, 解決手段効果表本文	0.99	0.991
アルゴリズム3 (ディープラーニング2)	要約用, 分類コード, 解決手段効果表本文	0.967	0.968
4つのアルゴリズムの多数決	要約用, 分類コード, 解決手段効果表本文	0.996	0.996

図7 PNFの学習処理の第二の処理結果の一部

## (2) 予測処理の処理結果

PNFにおいて、学習処理で構築された二値分類の学習モデルを用いて、ユーザが分類したい特許リストを与え、予測処理を行った結果の一部を図8に示す。

予測処理の結果は、分類対象の特許データ（ここでは、出願番号）ごとの分類結果（Class）とスコア（Score）とを有する。分類結果は、「1」または「-1」を採り得る。スコアは「0.5」から「1」を採り得る。

図8において、スコアが「0.5」等の低い特許に対しては、PNFの分類は信用ができないので、ユーザが確認する必要がある。しかし、スコアが「0.9」以上等の高い特許は、PNFの分類結果を信用しても良い、と考える。使用した学習モデルの精度が「0.812」とある程度高いからである。なお、学習モデルの精度が低い場合、人手で確認する必要がある分類対象の特許のスコアの閾値を下げるべきである。

1	出願番号	Class[PNF]	Score[PNF]
2	特願2014-255355	1	0.999810755
3	特願2014-111130	1	0.999876261
4	特願2014-110090	1	0.999992728
5	特願2014-108311	1	1
6	特願2014-103456	-1	0.5
7	特願2014-103329	-1	0.5
8	特願2014-101154	1	0.99998698
9	特願2014-099079	1	0.999998585
10	特願2014-098108	1	0.999826252
11	特願2014-098070	1	0.997815073
12	特願2014-097850	1	0.999999129
13	特願2014-097629	1	0.999983567
14	特願2014-097544	-1	0.5
15	特願2014-096206	1	0.999998759
16	特願2014-096118	1	0.999637008
17	特願2014-095462	1	1
18	特願2014-092754	1	0.999985086
19	特願2014-092186	1	0.999736723
20	特願2014-090707	1	1
21	特願2014-090271	1	1
22	特願2015-054436	1	1
23	特願2014-088612	1	0.999999962
24	特願2014-188451	1	1
25	特願2014-087405	-1	0.5
26	特願2014-086849	1	1
27	特願2014-085702	1	0.999022603
28	特願2014-085514	1	0.999594152
29	特願2014-084787	1	1
30	特願2014-084177	1	0.9999919
31	特願2014-083345	1	0.999982621
32	特願2014-082199	1	0.999962722
33	特願2014-076071	1	0.999970555
34	特願2014-075973	1	0.999995291

図8 PNFの予測処理の処理結果の一部

## 5 まとめ

最適学習モデル構築技術、および当該技術を採用する特許自動分類ツール（PNF）について紹介した。

いわゆるAI（ここでは、機械学習）を用いた特許自動分類の精度は100%になることは考えにくく、かつその精度は、評価してみないと分からないという性質、課題がAIにはある、と言える。

そのAIの課題を受け入れ、改善するための有力な技術が最適学習モデル構築技術である、と考える。

現在、BERTを含む4つの機械学習のモジュールを採用するが、各モジュールの精度を高めるための工夫、さらに精度の高いモジュールの開発を行い、最適学習モデル構築技術を用いた、特許自動分類の精度を高めていきたい。

## 参考文献

- 1) Kohavi, Ron (1995) . “A study of cross-validation and bootstrap for accuracy estimation and model selection” . *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence* 2 (12) : 1137-1143. (Morgan Kaufmann, San Mateo)
- 2) Jacob Devlin, Ming-Wei Chang, Kenton Lee, Kristina Toutanova (2018). “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”
- 3) 坂地泰紀他：Cross-Bootstrapping: 特許文書からの課題・効果表現対の自動抽出手法，電子情報通信学会論文誌 D, Vol. J93-D, No. 6, pp.742-755 (2010)
- 4) 邊土名朝飛他：特許構造を考慮したグラフベース教師なし重要技術語抽出，人工知能学会 全国大会 (2020)