

アジア特許情報研究会 設立10周年記念講演会

人工知能（AI）技術を活用した 特許分類付与支援の取組概要

2018年11月

特許庁 調整課
企画調査官 近藤裕之

特許・実用新案

年間出願件数：32万件

意匠

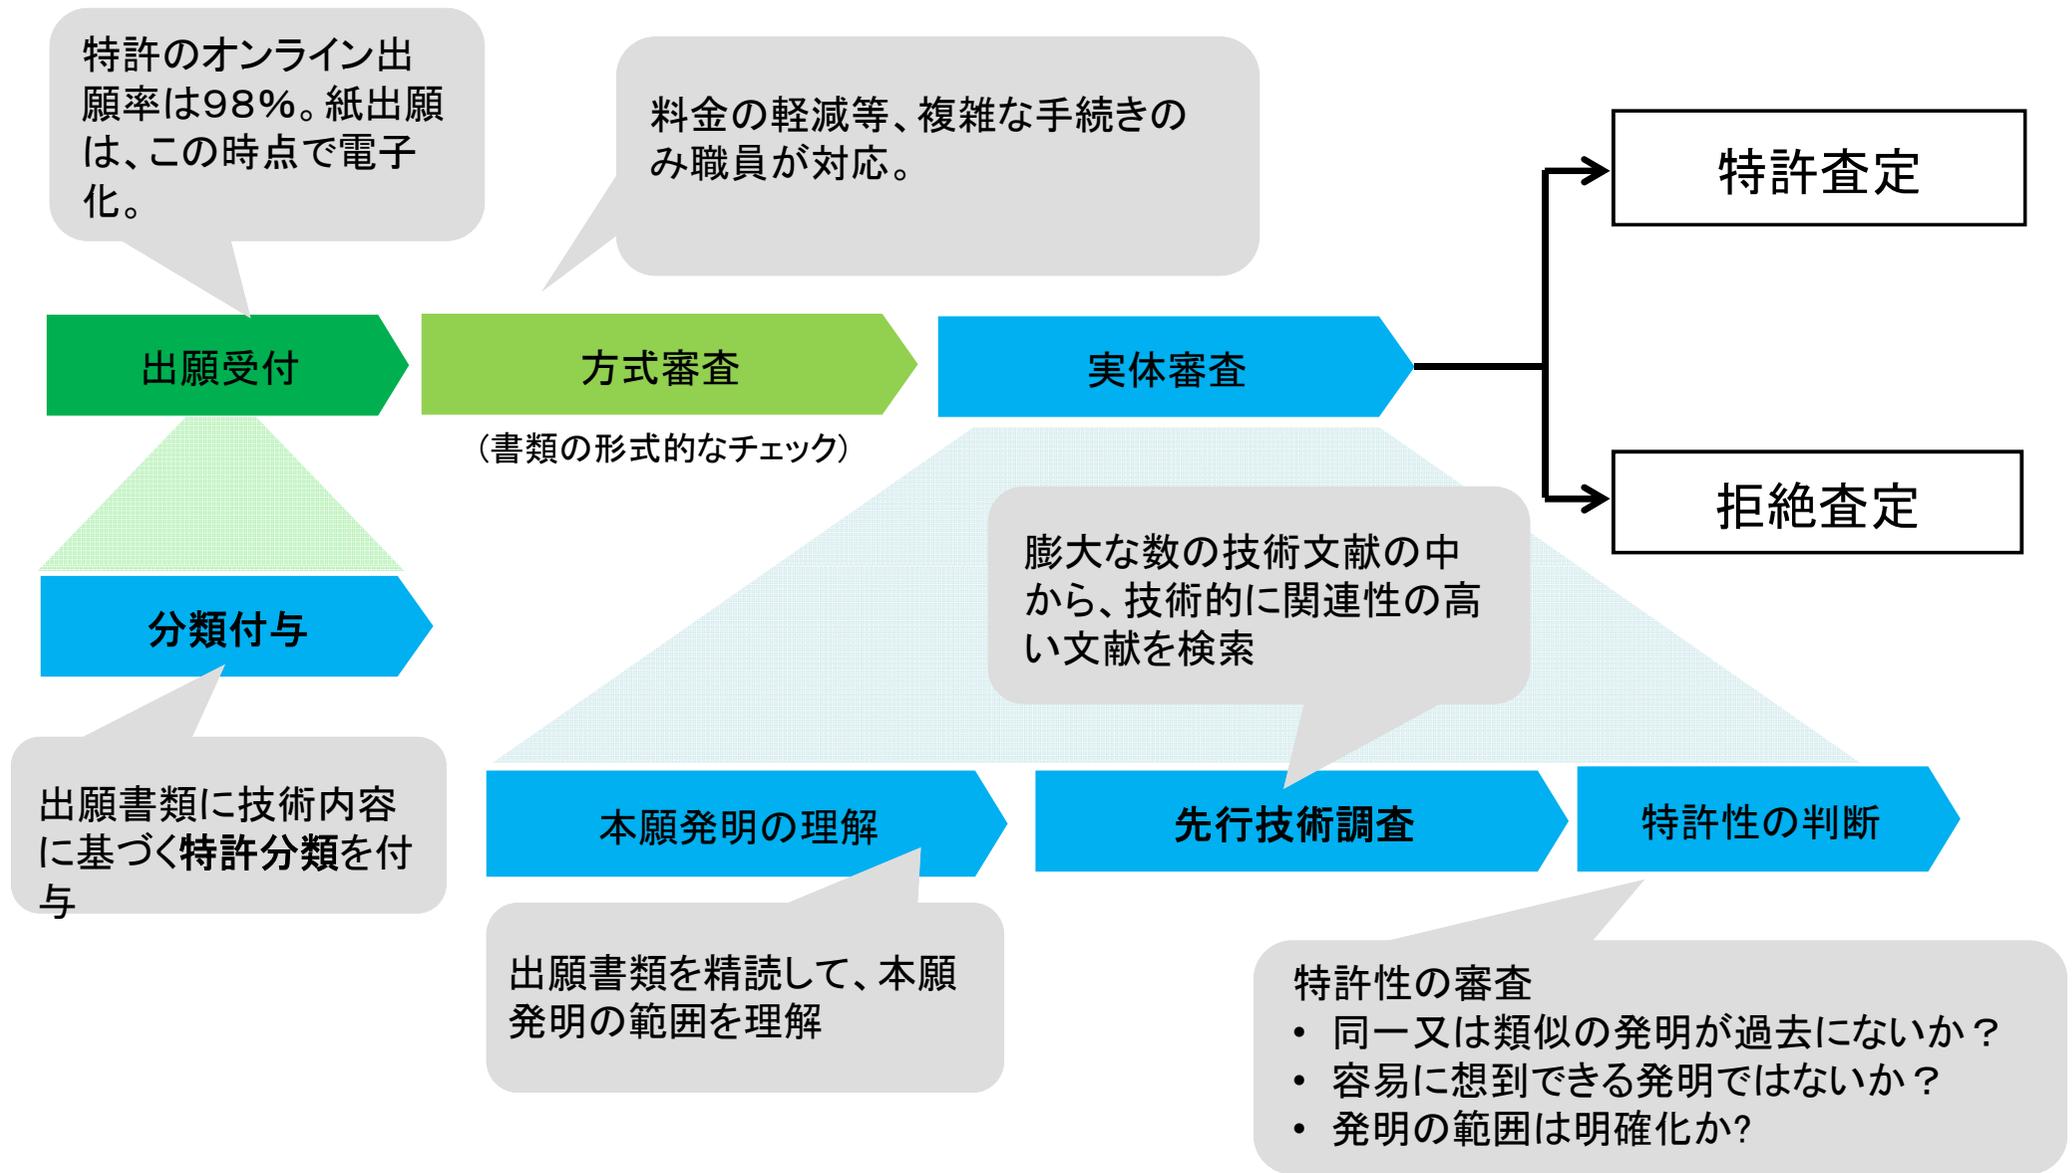
年間出願件数：3万件

商標

年間出願件数：19万件

- ✓ 特許庁では、2017年に54万件の出願を受け付け。
- ✓ 特許庁では、1990年にオンライン出願を受け付け開始。庁内業務のシステム化を段階的に推進。

特許審査業務の流れ



特許の概況

「**日本再興戦略**」改訂2014 ー未来への挑戦ー (p.58)

今後10年間で・・・「世界最速・最高品質」の審査を実現する。

政府
目標

<http://www.kantei.go.jp/jp/singi/keizaisaisei/pdf/honbun2JP.pdf>

「**知的財産推進計画2014**」 (p.7)

「世界最速・最高品質の特許審査」の実現

<http://www.kantei.go.jp/jp/singi/titeki2/kettei/chizaikeikaku20140704.pdf>

現状

世界の特許出願件数の推移



特許庁ステータスレポート2017 (P.34)

五大特許庁の審査官数の推移



特許庁行政年次報告書 2018年版 (P.11)

- 世界の特許文献数が急増
- 日本の特許文献シェアが大きく低下

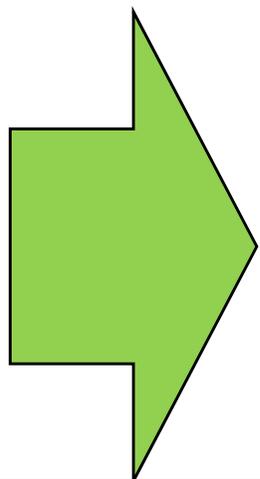


現状

① 内国特許文献



② 外国特許文献



将来

① 引例発見の蓋然性の高い領域



② 周辺領域に範囲を拡大

先行技術調査範囲の順序付けに**パラダイムシフトが必要**
(発行国による順序付けから内容オリエンティッドな順序付けにシフト)

業務の課題

特許出願される発明の複雑化
新たな技術分野の出現
審査官リソースが有限
検索対象文献数等の爆発的な増加
審査ノウハウの継承

AI技術の発展

機械学習
自然言語処理
深層学習

AI技術の活用による業務負担の軽減

目標

限られたリソースで高効率・高品質な業務の実現

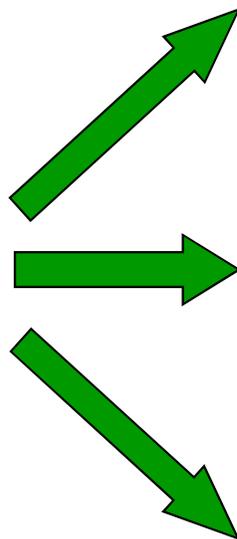
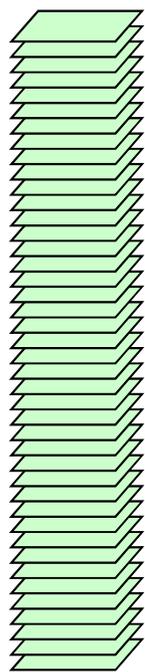
- ユーザーサービスの改善
- 職員の働き方改革の実現

平成28年度 特許分類付与 調査事業

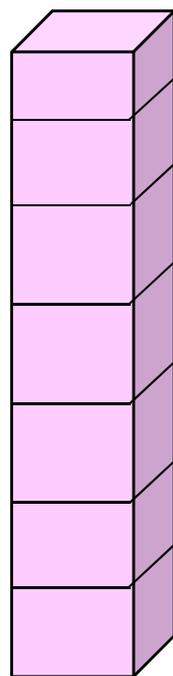
※ 事業名称「平成28年度 外国特許文献へのFターム等付与に関する機械学習活用可能性調査事業」

- 特許分類とは、文献を見つけやすく整理するために各特許文献を技術内容により分類して付与される記号。1文献に複数の分類がタグとして付与される。
- 図書館で本を借りる際にインデックスを目印にして目的の本を探すように、審査官は、世界中の数千万件の文献から、技術文献(特許性を判断するための証拠)を、特許分類を用いて探す。

国内特許公報



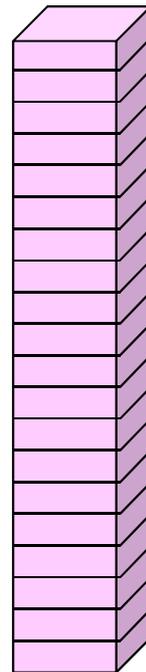
IPC (国際分類)



約7万項目

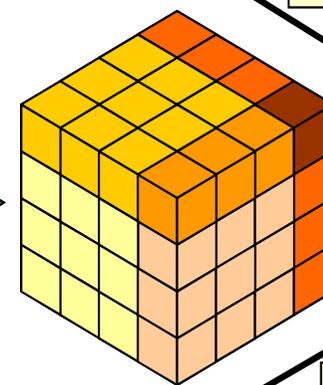


FI (日本分類)



約19万項目

Fターム (多観点の分類)



約36万項目

観点1(目的)
AA01, AA02, ...

観点2(用途)
BB01, BB02, ...

観点3(構成)
CC01, CC02, ...

国内文献だけでも庁内DBには
約3,700万件が蓄積されている
(年間約33万件ずつ蓄積)

分類の機能(役割)の例

1. 管理機能 (FI)

担当審査室を決定するための分類

2. 検索機能 (FI, Fターム)

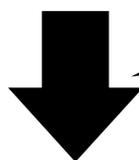
検索キーとしての分類

3. 表示機能 (FI)

発明情報として技術分野を表現するための分類

分類が必要な場面の例

1. 出願



1. FIによる
担当審査室決定

2. 審査

2. FI, Fタームを用いた
文献の絞り込み

理解



検索



判断



起案

3. 公開

3. 公報フロントページのFIによる
発明情報の表示

FIの実例

※各分類名は若干簡略化しています。

■ (セクション)

A: 生活必需品、B: 処理・運輸、C: 化学...

■ (サブセクション)

A0: 農業、A2: 食料品、A4: 家庭用品...

■ (クラス)

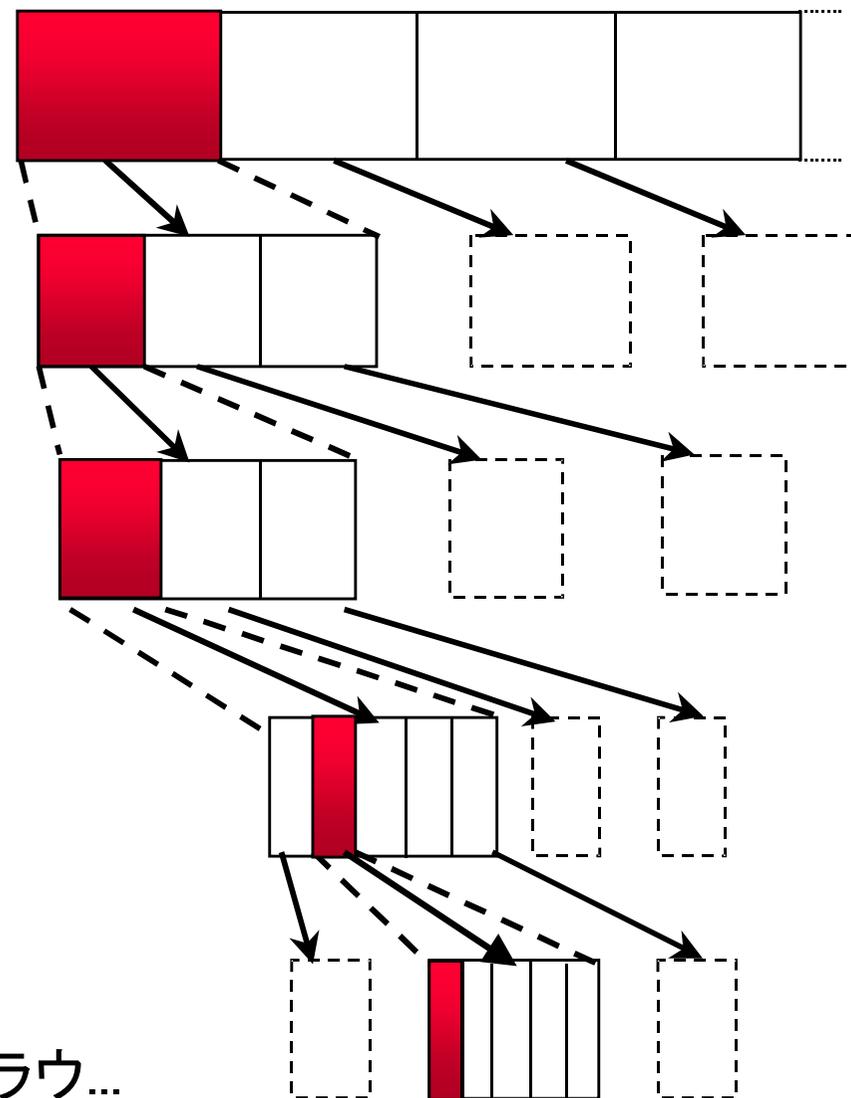
A01: 農業、A21: 베이킹、A22: 肉処理...

■ (サブクラス)

A01B: 土作業、A01C: 植付け、A01D: 収穫...

■ (メイングループ)

A01B1/00: 手作業具、A01B3/00: 固定刃プラウ...



Fタームの実例 テーマ3E003(容器詰包装操作)

3E003		容器詰包装操作								包装・容器
		B65B5/00 - 5/12								
AA	AA00 容器	AA01 ・剛性容器	AA02 ・一体の中仕切有	AA03 ・別体の中仕切有	AA04 ・緩衝保護材有(仕切優先)	AA05 ・柔軟性容器(袋)		AA07 ・フラップ有		AA10 ・その他
	AB	AB00 被包装物品	AB01 ・ブロック状物品	AB02 ・曲部を有するもの(円筒・球状等)	AB03 ・板状物品	AB04 ・曲部を有するもの(円板状等)	AB05 ・柔軟性容器による包装体		AB07 ・付属物(説明書等)	
BA		BA00 容器詰操作— 容器の取扱い—	BA01 ・容器の取り出し	BA02 ・容器の供給(容器詰時)	BA03 ・間欠的供給	BA04 ・連続的供給	BA05 ・上下方向の供給	BA06 ・容器の開閉	BA07 ・容器の閉鎖	
	BB	BB00 容器詰操作— 被包装物品の供給—	BB01 ・物品の繰り出し	BB02 ・物品の単列供給	BB03 ・物品の複列供給	BB04 ・物品のグループの形成	BB05 ・集積状態を小さくするもの			
BC		BC00 容器詰操作— 被包装物品の取扱い—	BC01 ・単一の操作で単数の物品の取扱い	BC02 ・単一の操作で複数の物品の取扱い	BC03 ・挿入方向に単列[x]	BC04 ・挿入方向に単行[y]	BC05 ・単列・行で積重ね[z]	BC06 ・複数行列[x, y]	BC07 ・複数行列の積重ね[x, y, z]	
	BD	BD00 容器詰操作— 既製容器を用いて—	BD01 ・物品を容器上方から挿入	BD02 ・シュート、コンベヤによる	BD03 ・シャッターの開閉による	BD04 ・把持体による	BD05 ・物品を側方から容器へ	BD06 ・物品を下方から容器へ	BD08 ・容器を物品へ	
BE		BE00 容器詰操作— 容器の組立を伴う—	BE01 ・セッティング	BE02 ・ラウンド						
	CA00 検知対象	CA01 ・容器	CA02 ・被包装物品	CA03 ・個数	CA04 ・物品	CA05 ・物品	CA06 ・物品			

容器、被包装物品、容器詰操作、検知対象、

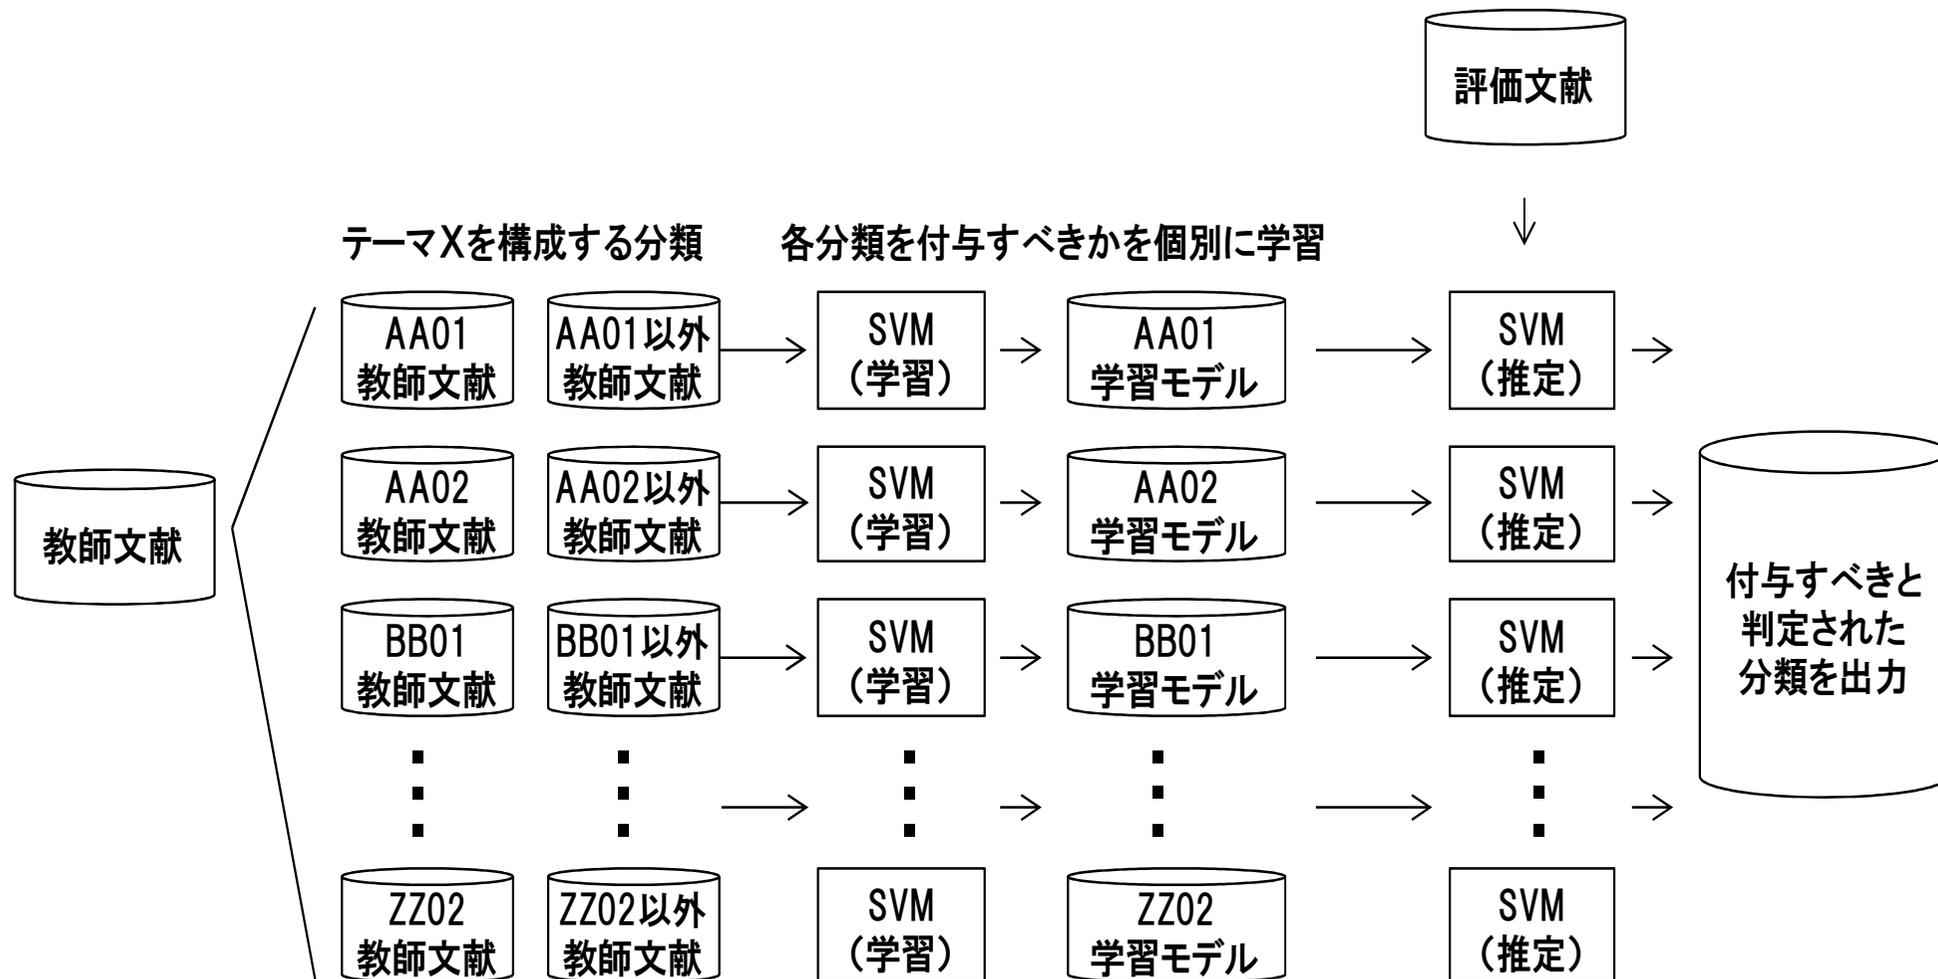
制御手段、制御対象、目的・効果の各観点による細展開



- SVM(サポートベクターマシン)(One-vs-rest方式)による分類付与方式

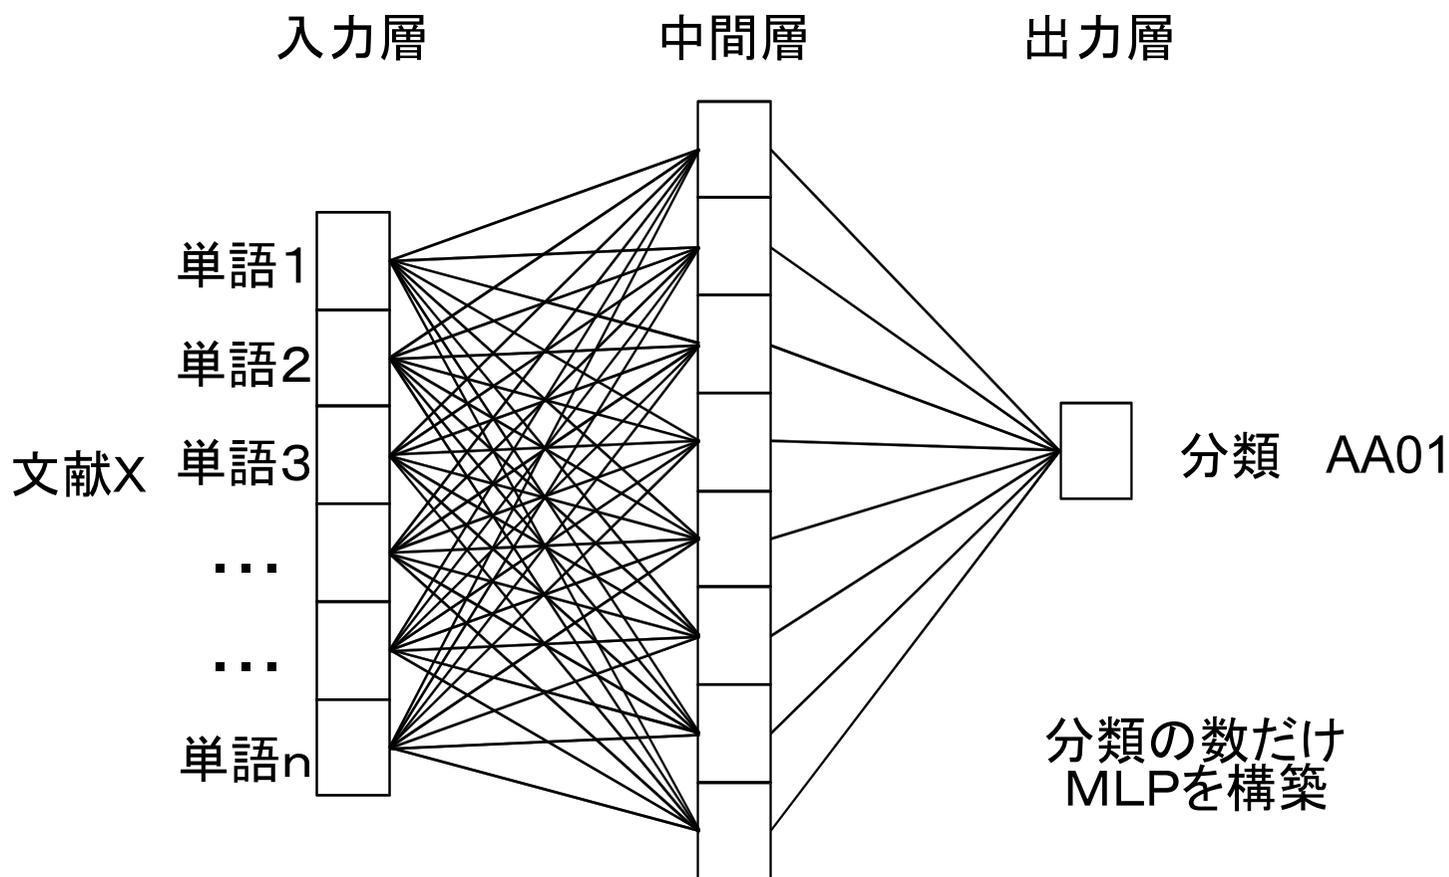
2クラスを識別する機械学習モデル(2値分類モデル)であり、2クラスを識別する学習モデルを教師文書から生成し、新規文書に対してどちらのクラスに属するかを識別。

特許分類付与は、1つの特許文献に1つ以上の分類が付与されるマルチラベル分類であるため、「One-vs-rest方式」と、「One-vs-one方式」があるが、「One-vs-rest方式」を採用。



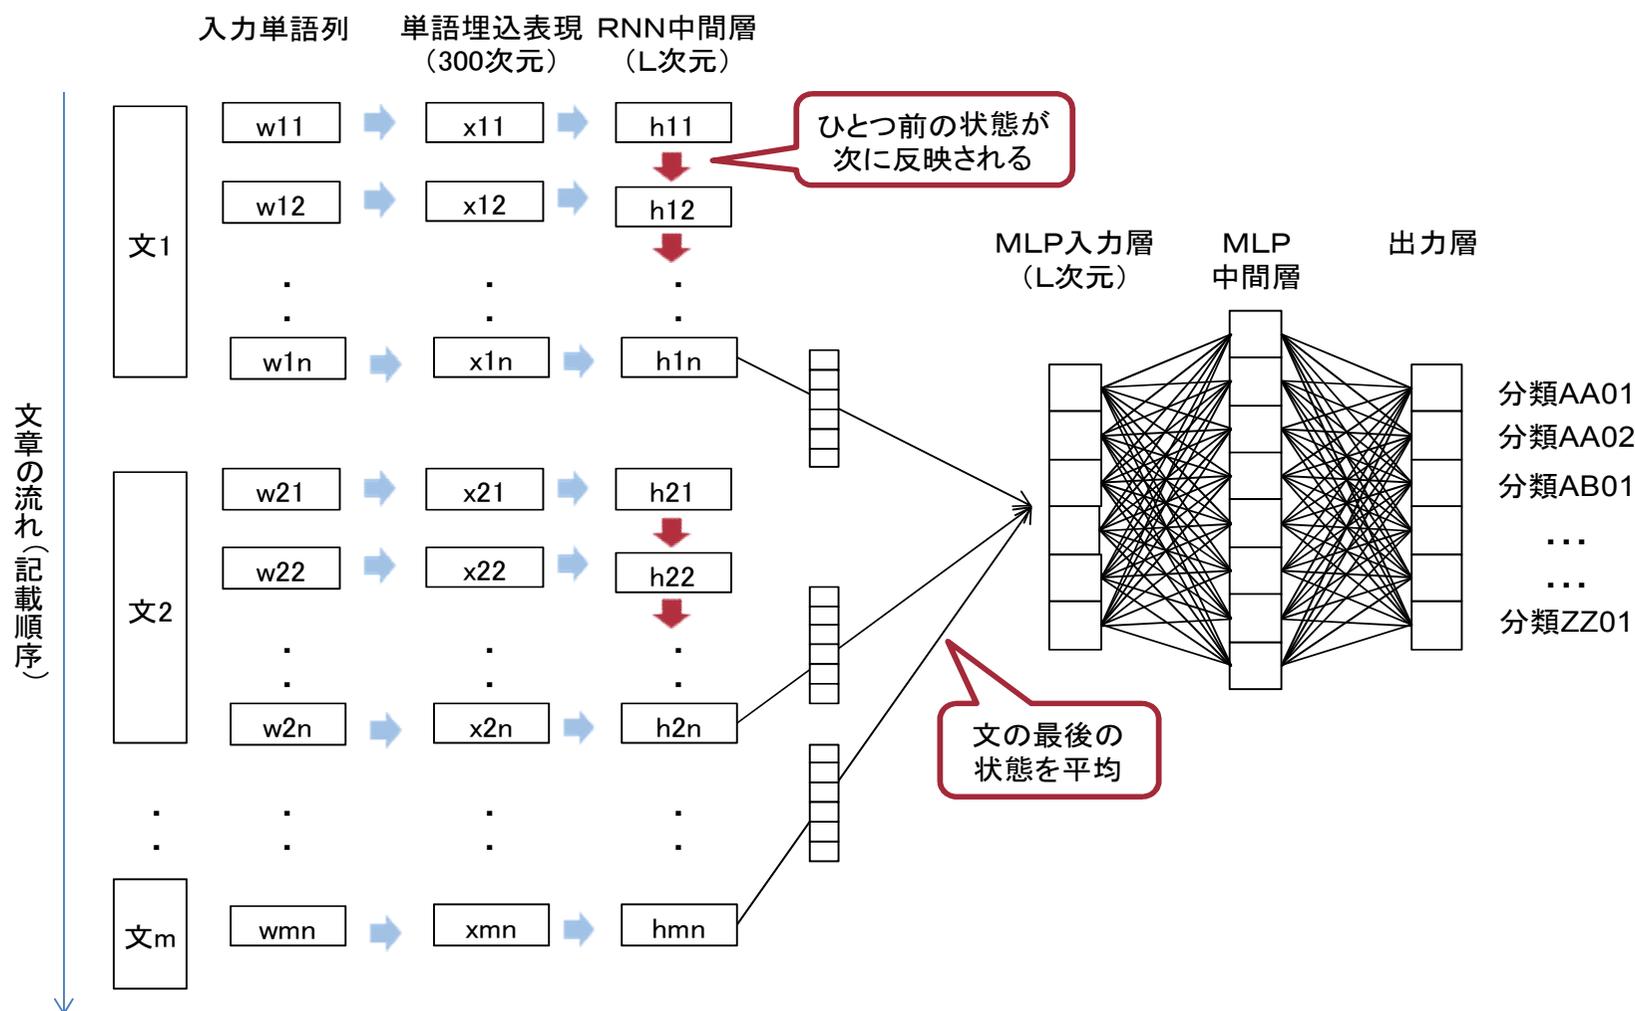
- MLP(多層パーセプトロン)(個別付与方式)による分類付与方式

入力層、出力層と、1層以上の中間層(隠れ層)から構成される。MLPでは、入力層のノードと中間層のノード、中間層のノードと出力層のノードが全結合した構成となっており、学習時には、出力データと教師データの差分(誤差)に基づいて、中間層のノードの重み値を更新するバックプロパゲーション(誤差逆伝搬学習法)が採用される。



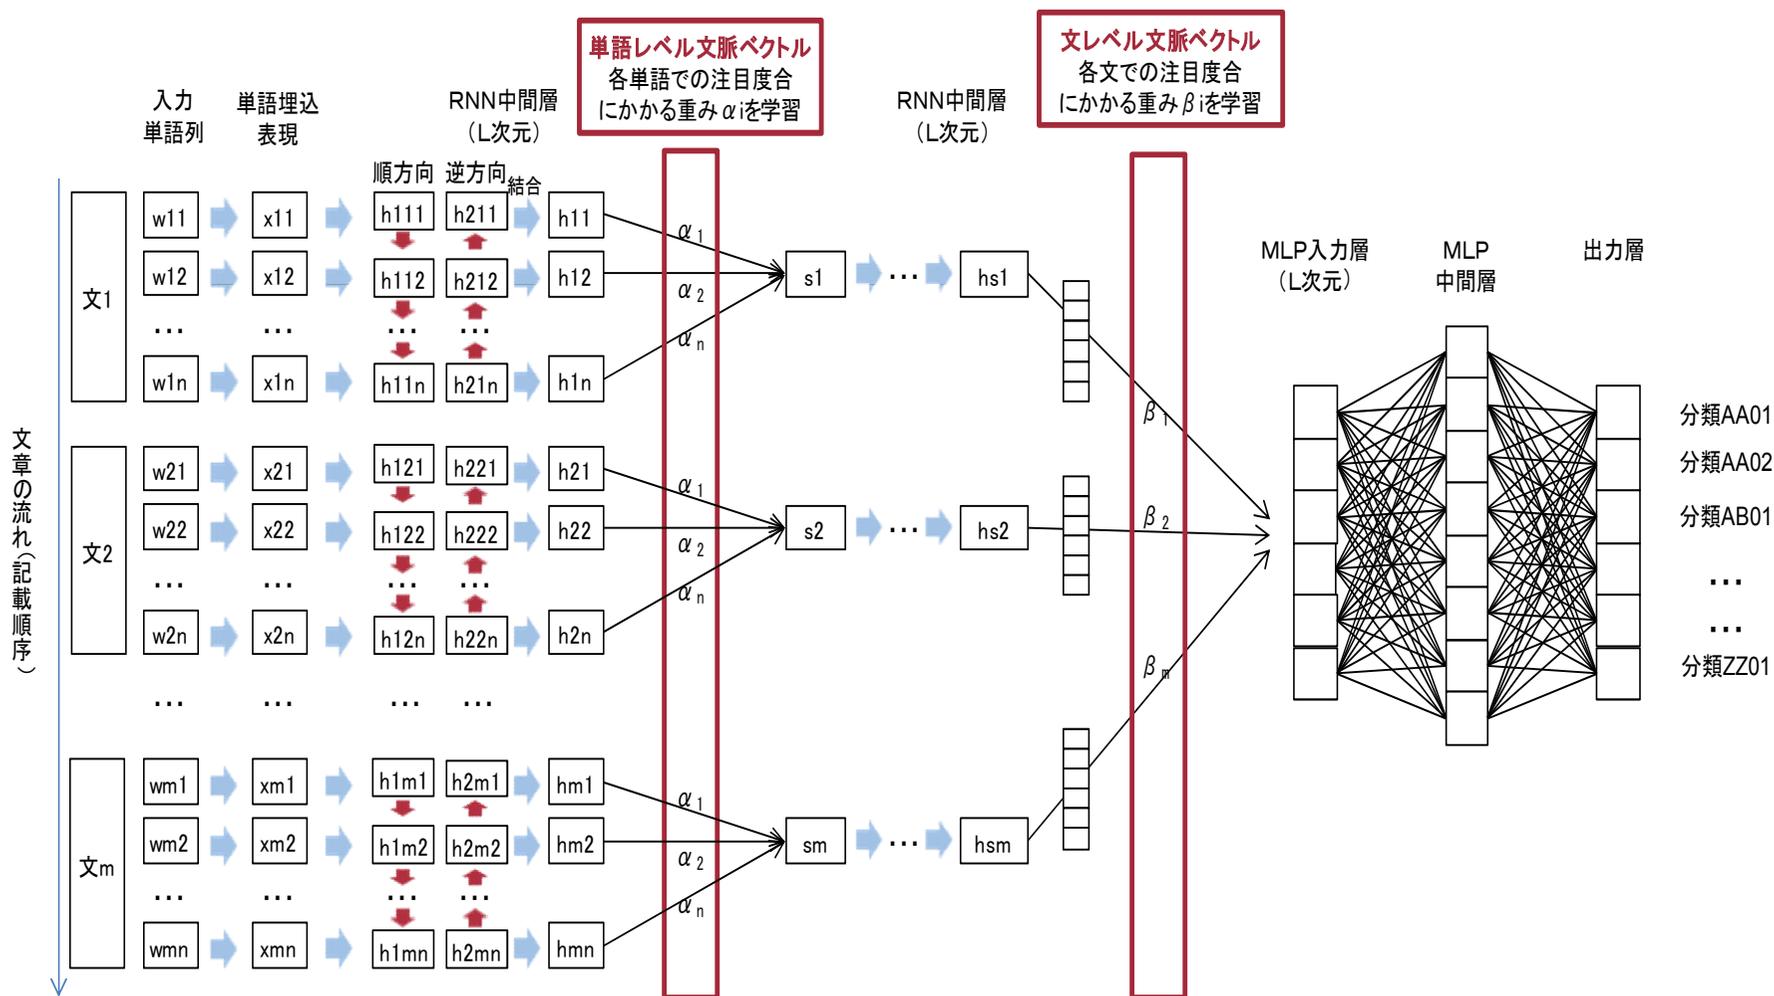
- RNN(リカレントニューラルネットワーク)による分類付与方式

文章の記載順序を保持して学習することにより、文章の記載順序を考慮した学習を可能としたニューラルネットワークであり、中間層を構成するノードにおいて、ひとつ前までのノードの情報(の一部)を、次のノードに反映させることにより、文章の記載順序を反映した学習ができるもの。



- NAM(ニューラルアテンションモデル)による特許分類付与方式**

RNN(リカレントニューラルネットワーク)において、文献に現れる各単語の注目度合(Attention)を学習し、分類付与に貢献する単語とそうでない単語を識別し上で分類を付与するニューラルネットワークであり、分類を付与する根拠となった記載個所を学習して分類を付与できるという特徴を有する。



以下の条件にてFI・Fタームの推定精度を評価

- 対象言語: SVM, MLP, RNN => 原文(英語、中国語、ドイツ語) 及び 機械翻訳文(日本語)
NAM(学習に時間がかかったため) => 英語
- 解析対象: SVM, MLP, RNN => 全文 及び 要約
NAM(学習に時間がかかったため) => 要約

	高			低
付与精度 (※1)	SVM	MLP	RNN	
付与精度 (※2)	SVM	NAM	MLP	RNN

※1 いずれの対象言語の場合、及び 解析対象の場合であっても各手法の精度の順位傾向は同じ。

※2 対象言語は英語で、解析対象は要約の場合。

特性1

分類付与根拠が、特許文献のごく一部の記載個所にしか現れないため、他の記載個所に含まれる単語が、ノイズ語となって、誤付与を引き起こす。
付与精度向上のために、分類付与根拠の記載個所を特定。ノイズ語がなくなる。

特性2

分類付与根拠が、句・文・段落といった単位で付与根拠が記載されている場合がある。
付与精度向上のために、単語の埋め込み表現ベクトルをフレーズ・文・段落単位で平均したベクトルを素性として使用する。

特性3

分類付与根拠が、高頻度で使用されている単語の組合せによって記載されている場合、どの文献にも出現しているため、特定の分類を特徴付ける単語となりにくい。
付与精度向上のために、特性2と同様、単語単位で学習するのではなく、フレーズ・文・段落といった単位で学習する。

特性4

分類付与根拠が、教師文献にも含まれていない、あるいは含まれているとして極めて出現頻度が低いため、学習結果が反映されにくい特殊な語彙または表現によって記載されている場合。
付与精度向上のために、類義語辞書の活用で処理することも考えられるが、類義語辞書にも登録されていないような特殊な語彙を吸収することは技術的には難しい。

特性5

教師文献における付与文献数(正例)が少ない分類。
付与精度向上のために、教師文献を増やしてその分類が付与されている文献数を増やす。
その際、正例と負例のバランスも調整が必要。

特性6

FI・Fタームにおける分類階層が低い(ドット数が多い)分類になるほど、分類定義の粒度が細くなるため、分類付与が難しくなる。
付与精度向上のために、付与する分類を上位の階層の分類とする。

特性7

他の分類のどれにも該当しない文献の寄せ集めである「その他」に相当する分類。
どれにも該当しない分類の特徴を学習することは難しいが、「その他」と兄弟関係にある分類のどれも付与されなかった文献に付与する、といった付与方式が考えられる。

特性8

発明の技術傾向(トレンド)が頻繁に変化する場合、教師文献の収集が追い付かないため、付与精度が向上しない。

平成29年度 特許分類付与 調査事業

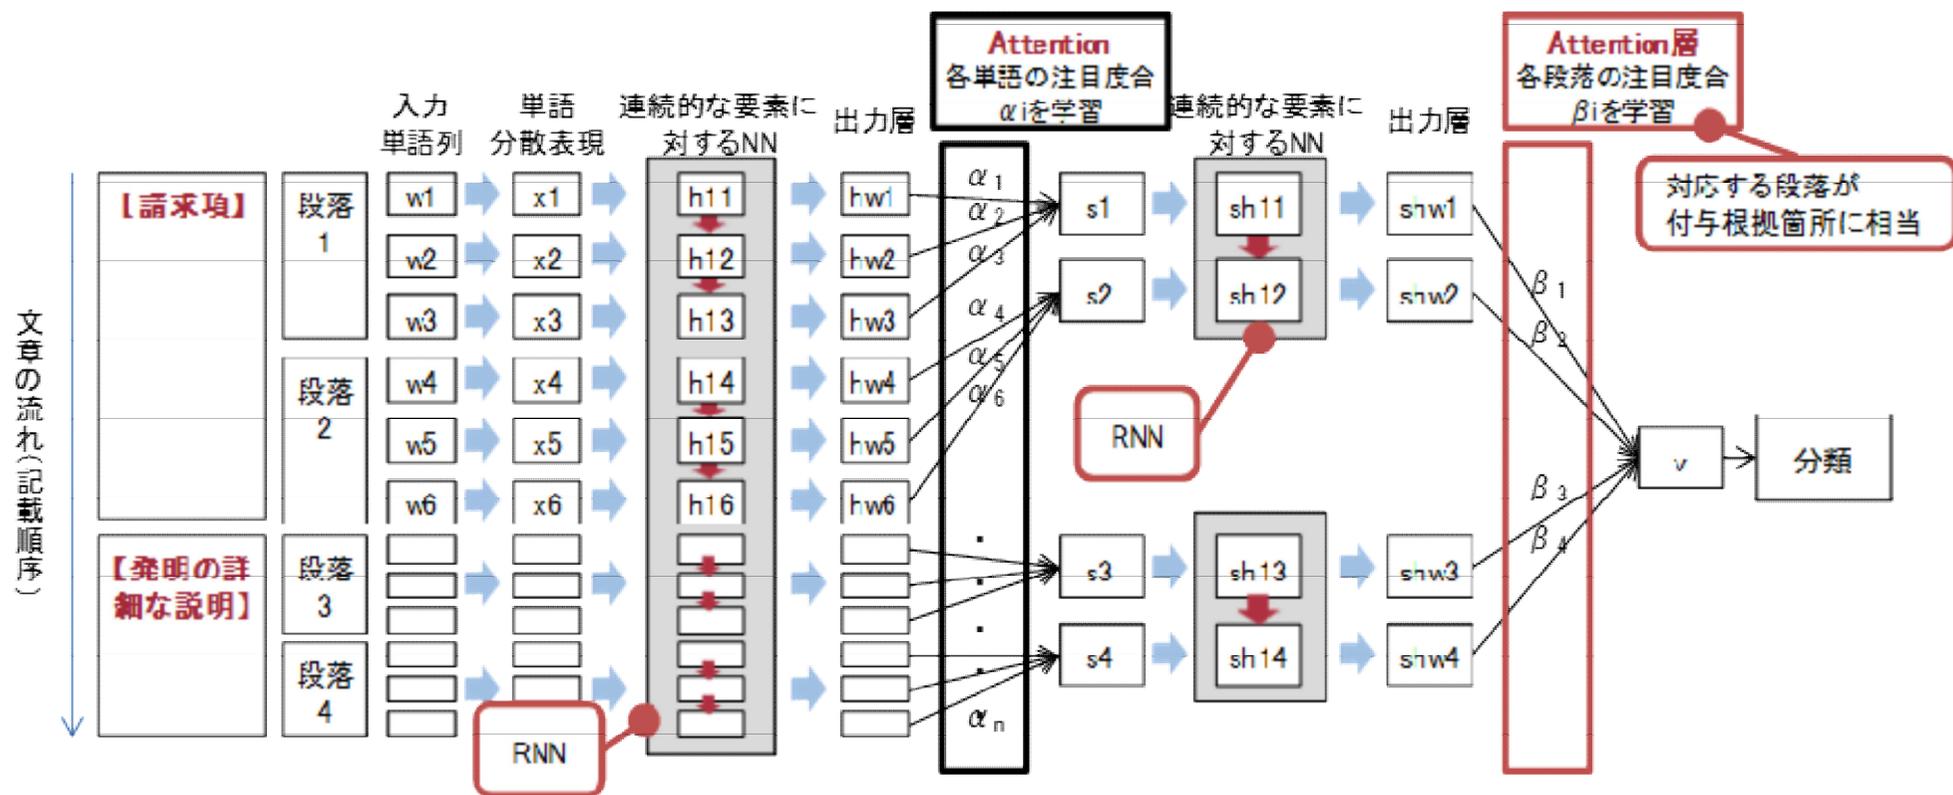
※ 事業名称「平成29年度 Fターム等付与支援システム実用化に向けた実証的研究事業」

※検証 1 の機械学習モデル : 人手で作成した付与根拠データを機械学習に用いない

• NAM(ニューラルアテンションモデル)

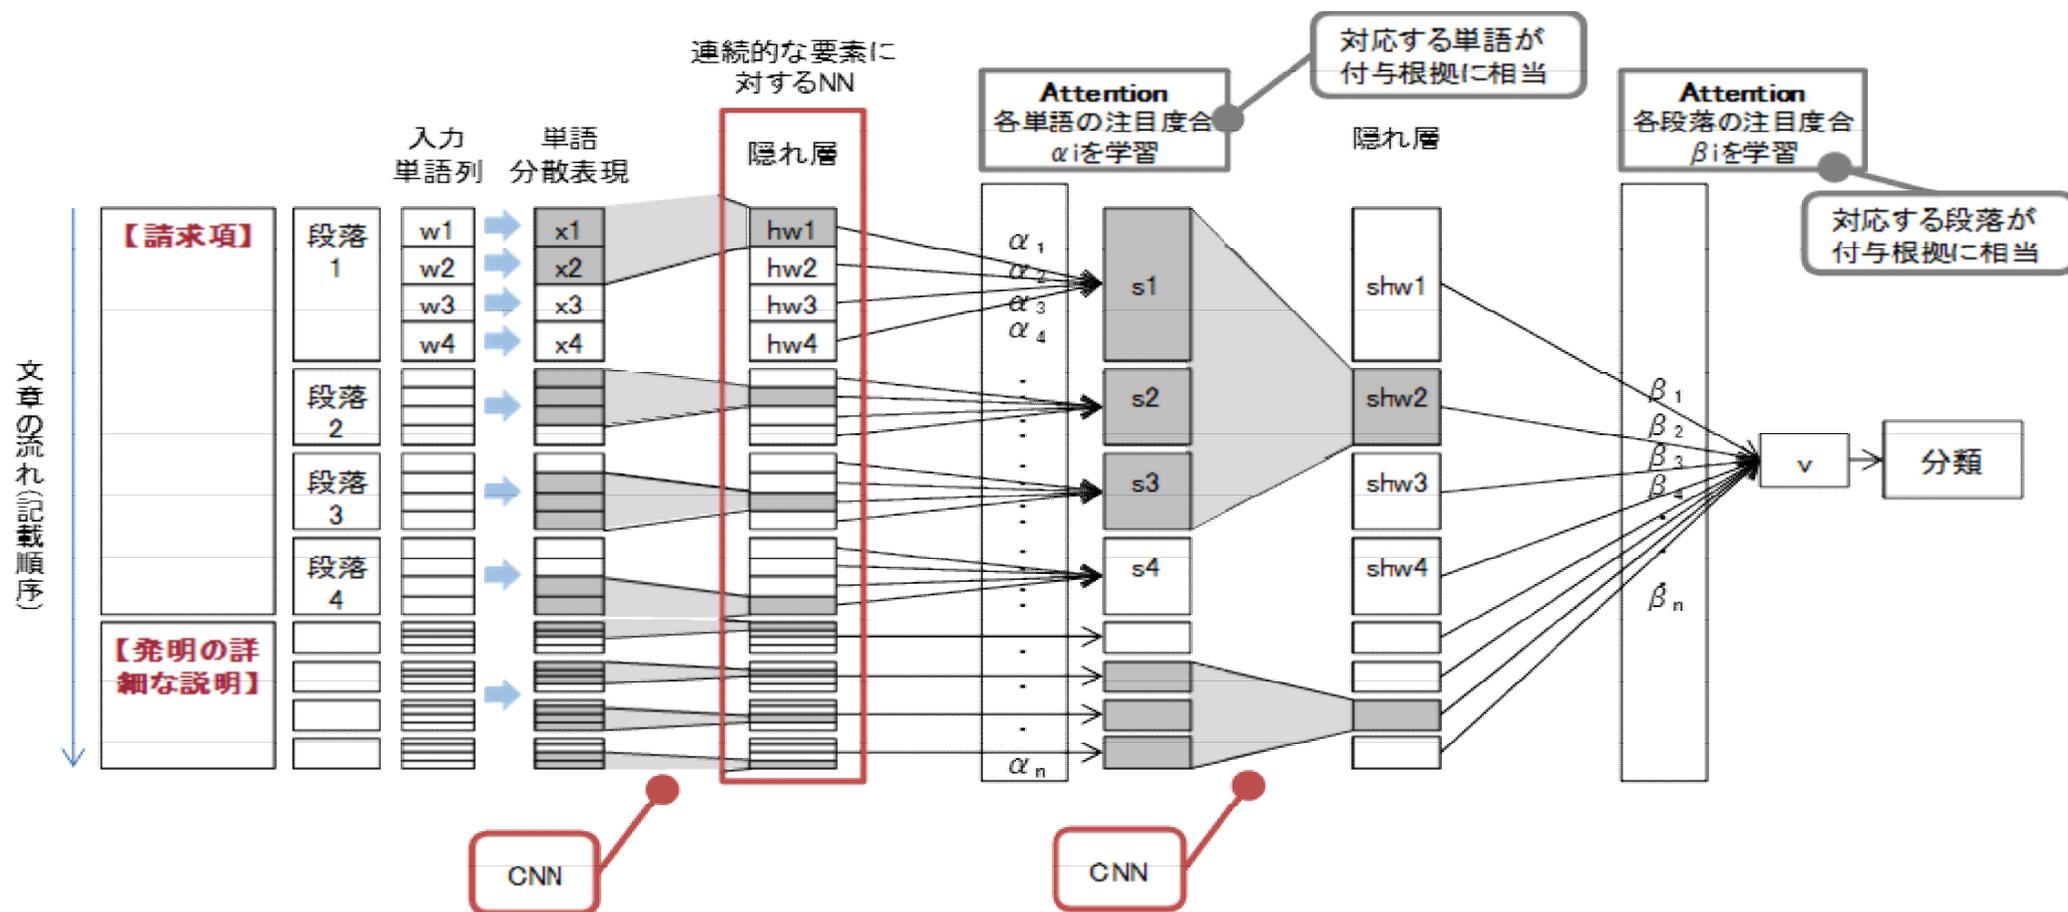
文献に現れる各単語の注目度合(Attention)を学習して、分類付与に貢献する単語と、そうでない単語を識別した上で分類を付与し、単語ごとに文脈を考慮した表現を抽出するための「連続的な要素に対するニューラルネットワーク(NN)」と、文脈を考慮した表現をもとに、各単語の注目度合を表す値を得るための「注目度合を決定するAttention層」から構成される。

どの記載個所に注目すると最終的なFターム付与精度が向上するのかという情報を元に、注目の仕方を学習する。



※検証 1 の機械学習モデル : 人手で作成した付与根拠データを機械学習に用いない

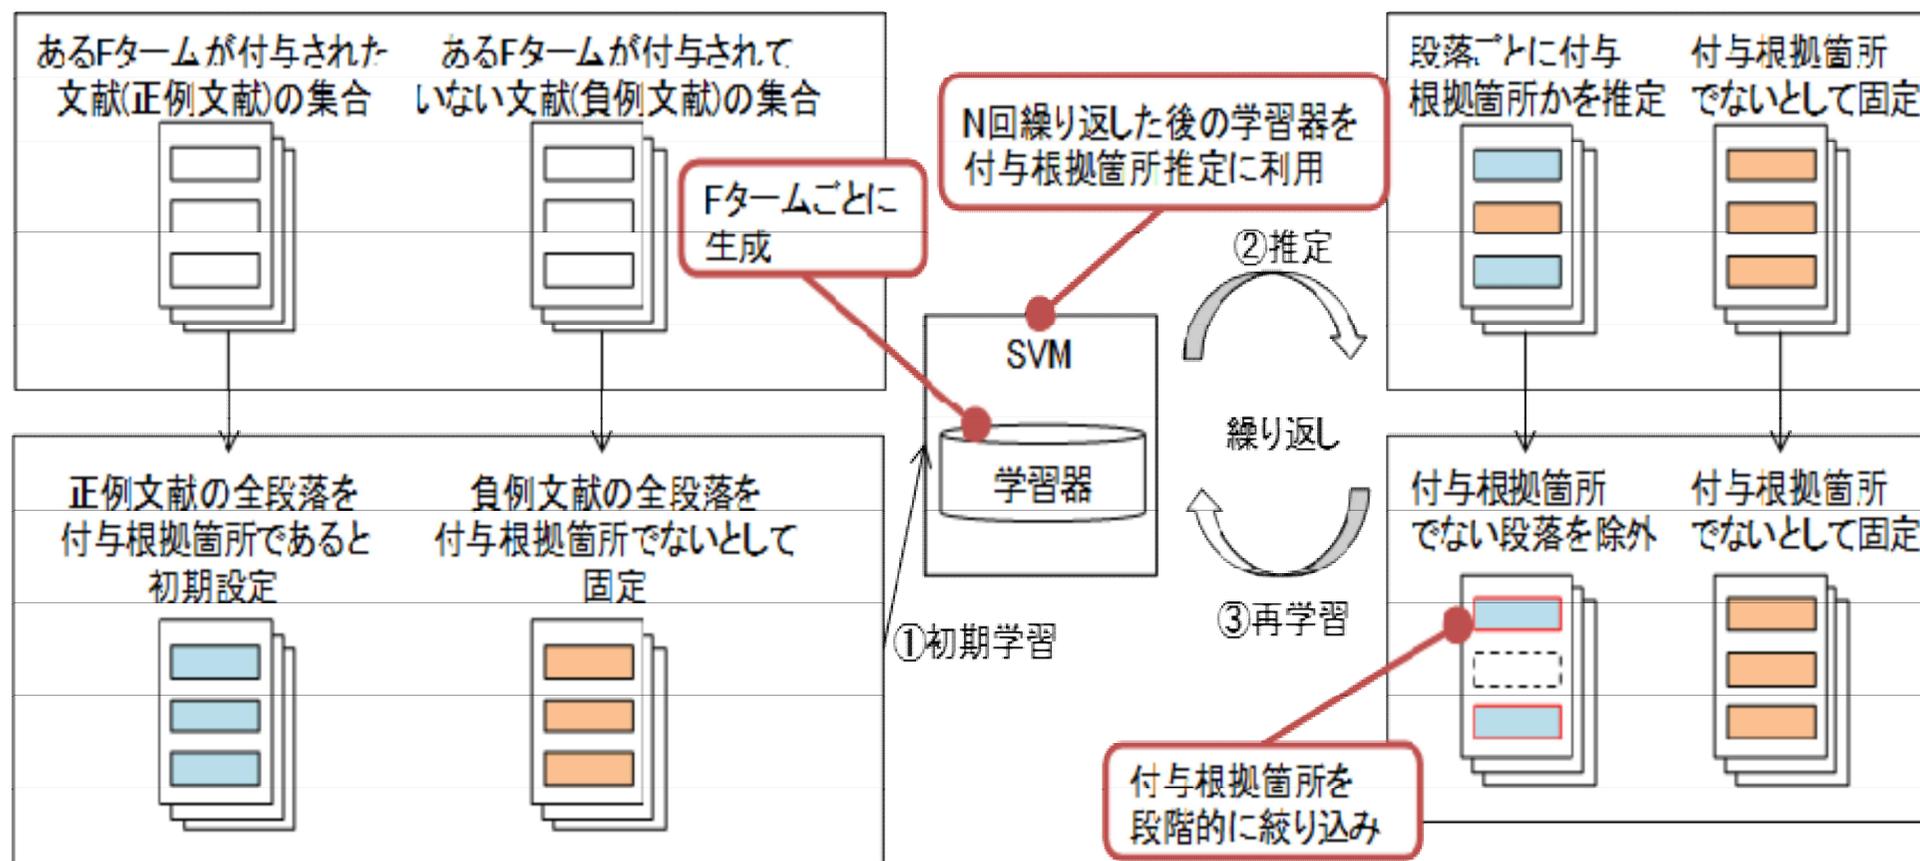
- CNN-NAM(畳み込みニューラルアテンションモデル)
NAMの隠れ層を、CNNに置き換えたニューラルネットワーク。
NAMと比較し、並列処理によって学習を高速化でき、マシンリソースも削減できる。



※検証 1 の機械学習モデル : 人手で作成した付与根拠データを機械学習に用いない

- mi-SVM(マルチインスタンスサポートベクターマシン)

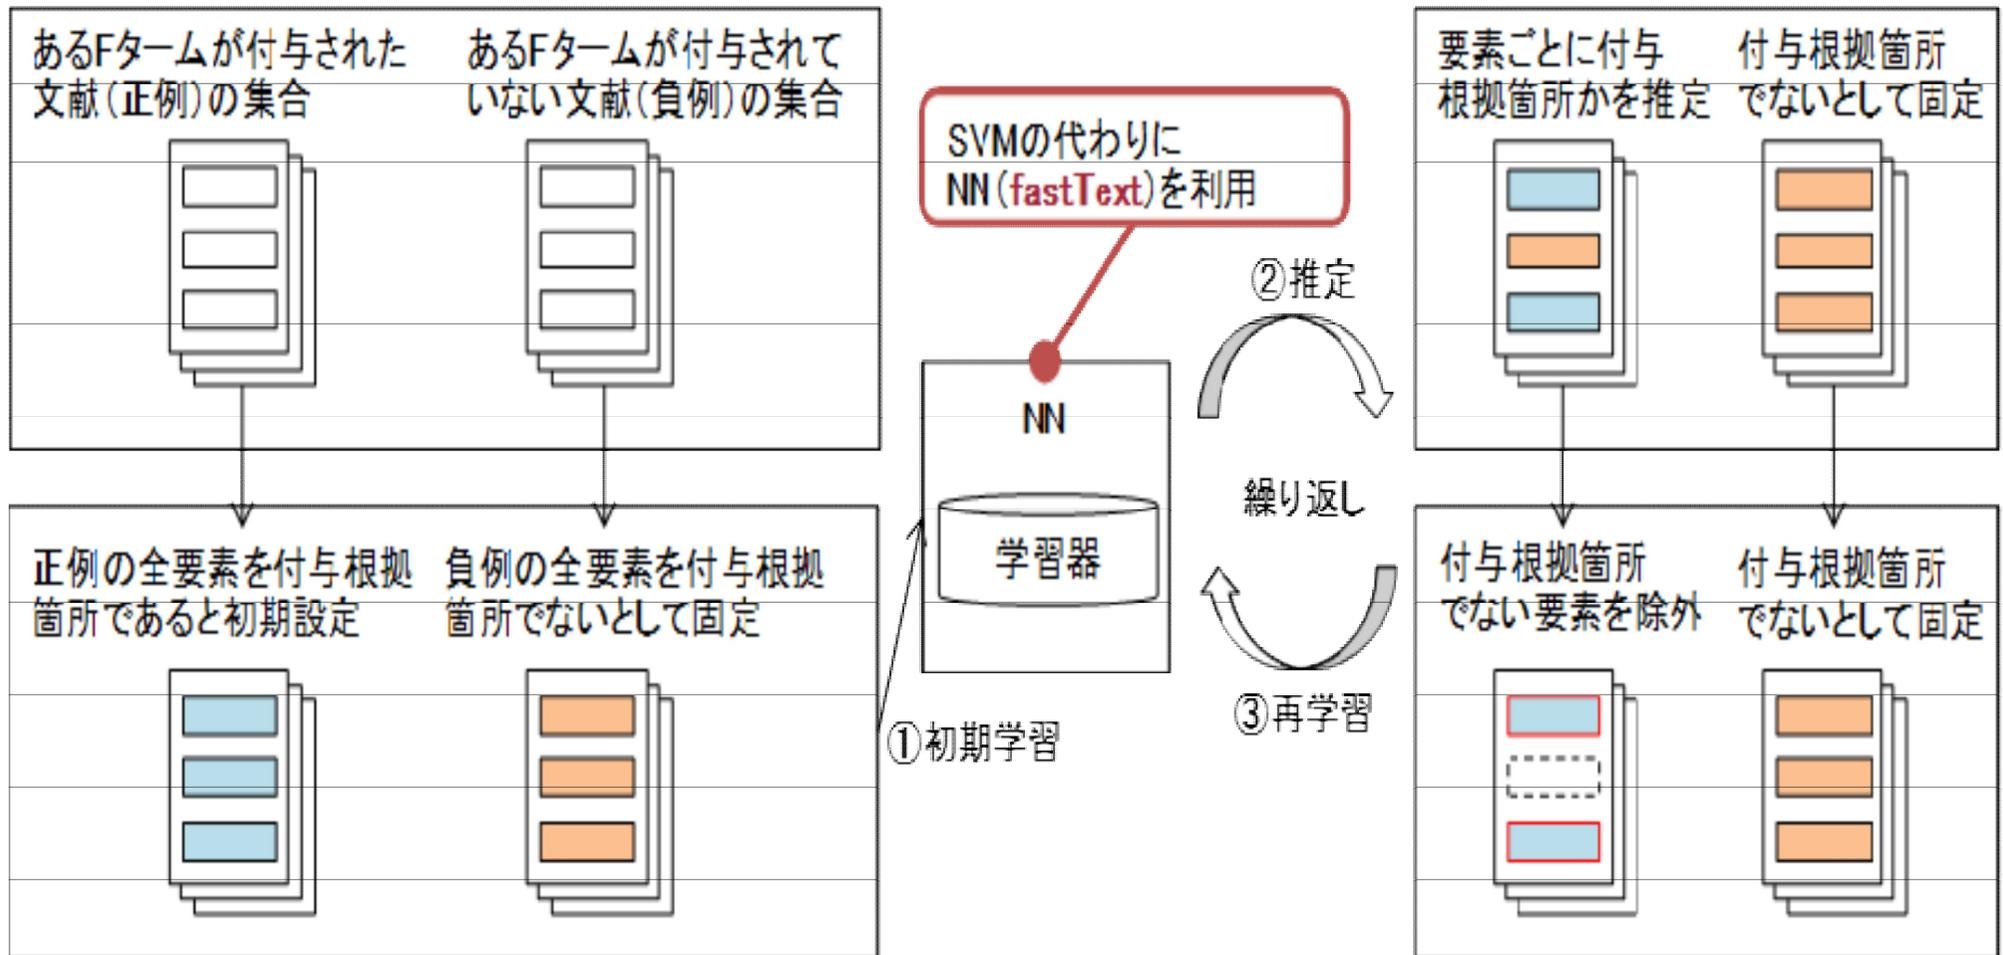
各段落が付与根拠箇所とみなされるかFタームごとに推定し、付与根拠箇所とみなされない段落を除外しては再学習するという処理を繰り返すことにより、付与根拠箇所を絞り込んでいく機械学習モデル。



※検証 1 の機械学習モデル : 人手で作成した付与根拠データを機械学習に用いない

- mi-NN(マルチインスタンスニューラルネットワーク)

mi-SVMにおいてSVMの代わりに、ニューラルネットワークモデルfastTextを適用したモデル。
他の学習手法と比べて学習の時間が短い利点がある。



以下の条件にて付与根拠箇所(特許公報)の推定精度を評価

- 対象技術分野: 12の技術分野(テーマ)
- 対象Fターム: 技術分野(テーマ)あたり20個のFターム
- 対象文献 : 日本語の公開特許公報
- 精度評価文献: 各テーマ200件の評価文献(正解データ)
- 評価指標: 根拠箇所推定精度(F値)、抽出率

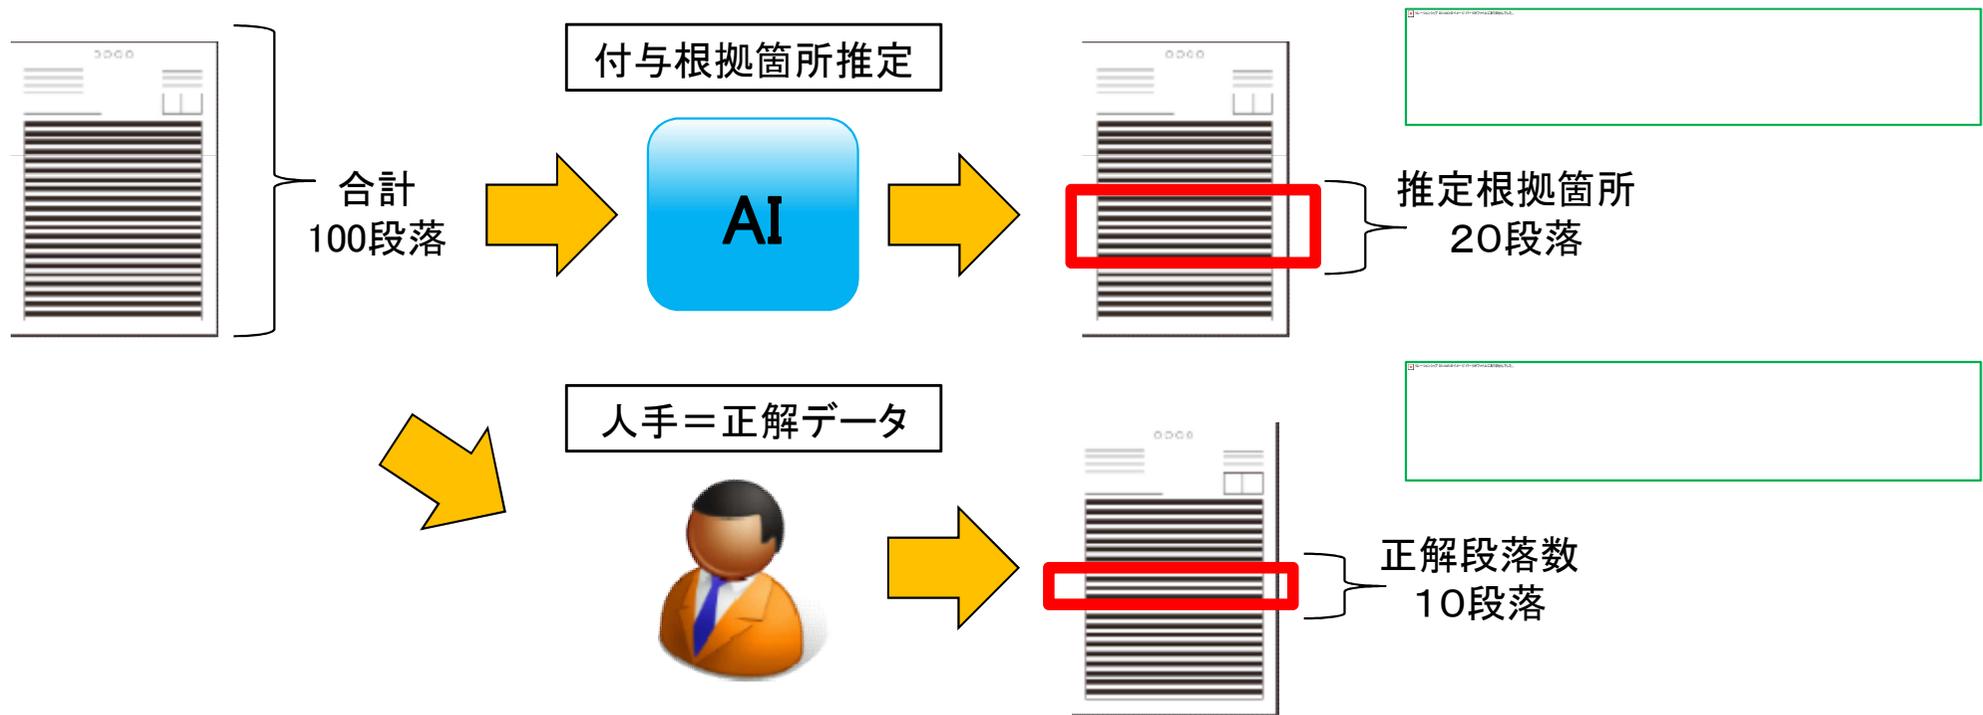
	高			低
根拠箇所推定精度	mi-SVM	NAM	CNN-NAM	mi-NN
抽出率 (正解との類似度)	mi-SVM	mi-NN	NAM	CNN-NAM

※抽出率 : 次ページを参照

<抽出率の定義>

評価文献の総段落数に占める、付与根拠としてA Iが推定した段落数の割合

- 人手の正解データと機械推定した付与根拠箇所の抽出率とを比較することで、機械がどれだけ付与根拠箇所を絞り込めているか（あるいは、過度に絞り込んでいないか）の評価が可能



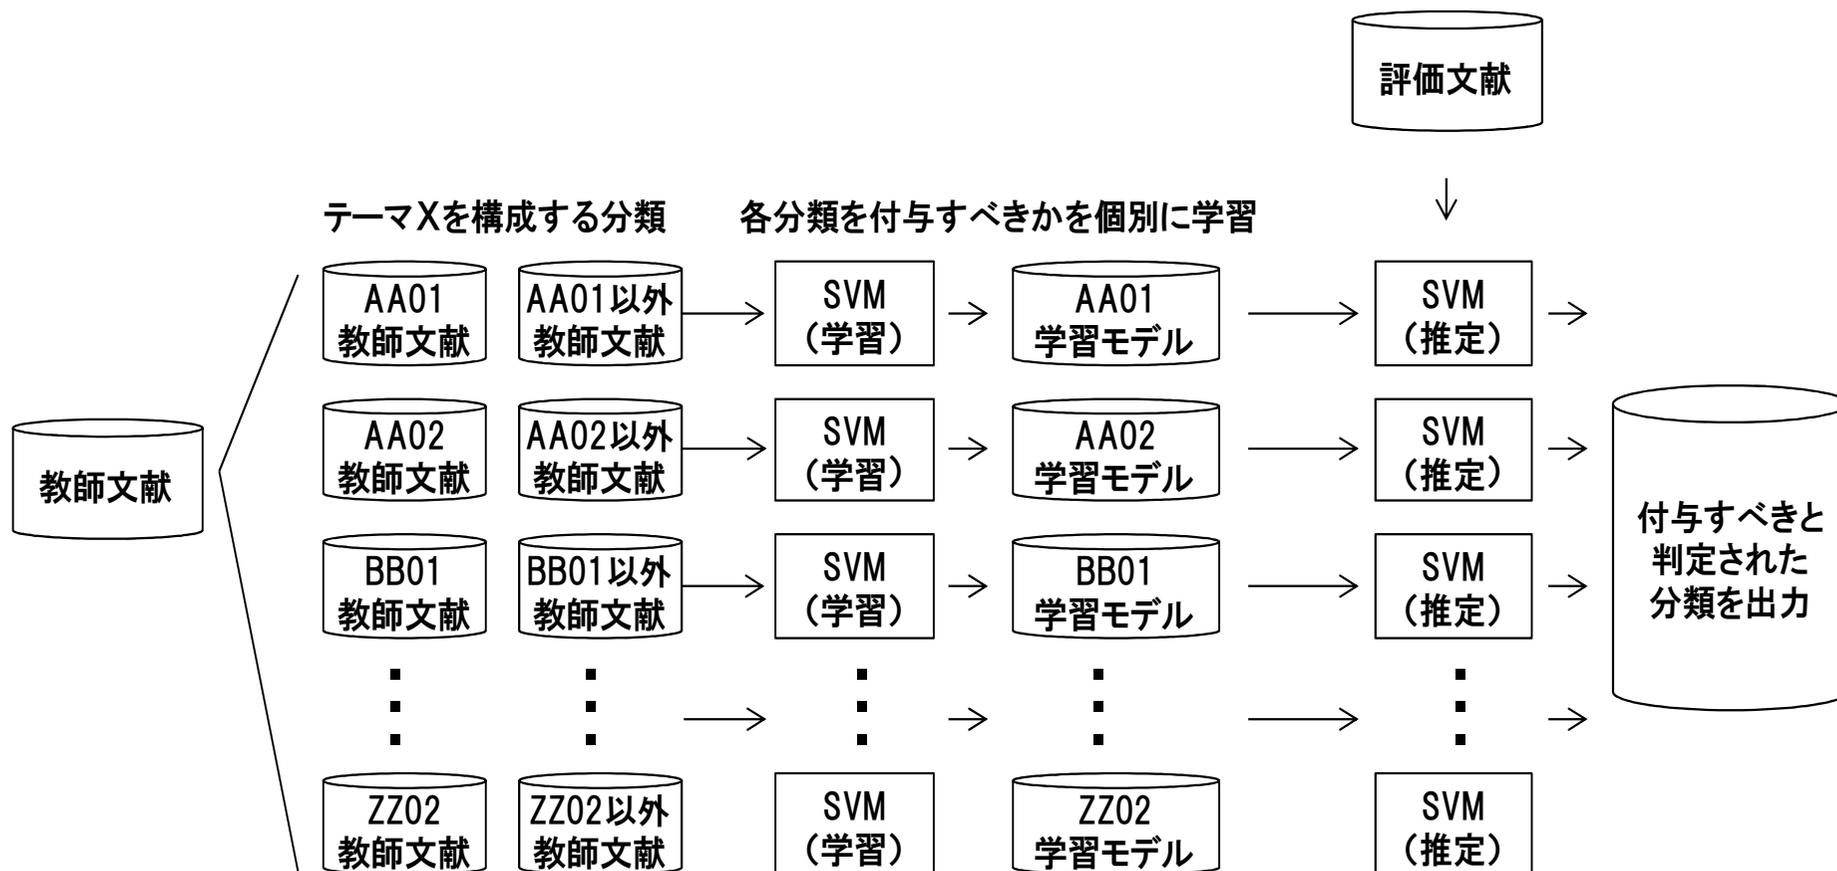
上記例：AIの抽出率 > 正解抽出率 → AIが適切に絞り込めていない

※検証2の機械学習モデル：人手で作成した付与根拠データも機械学習に利用

- SVM(サポートベクターマシン)(One-vs-rest方式)による分類付与方式

2クラスを識別する機械学習モデル(2値分類モデル)であり、2クラスを識別する学習モデルを教師文書から生成し、新規文書に対してどちらのクラスに属するかを識別。

特許分類付与は、1つの特許文献に1つ以上の分類が付与されるマルチラベル分類であるため、「One-vs-rest方式」と、「One-vs-one方式」があるが、「One-vs-rest方式」を採用。

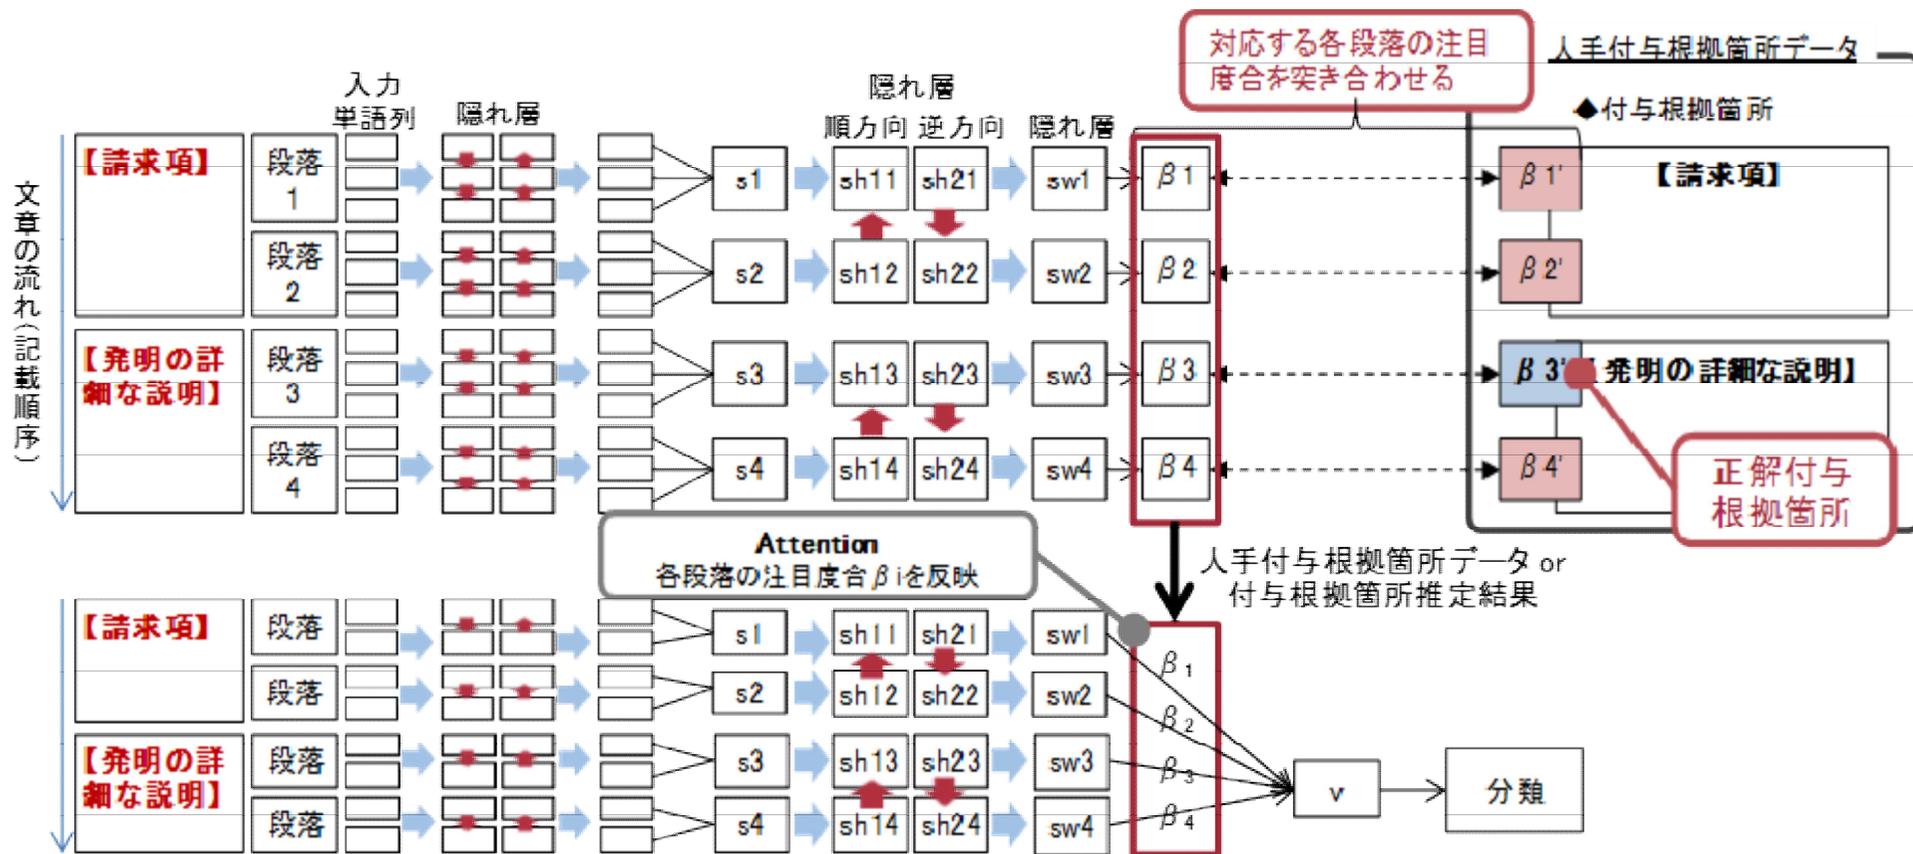


※検証 2 の機械学習モデル : 人手で作成した付与根拠データも機械学習に利用

• NAM+(ニューラルアテンションモデル+)

NAMを以下2つのネットワークに分割したモデル

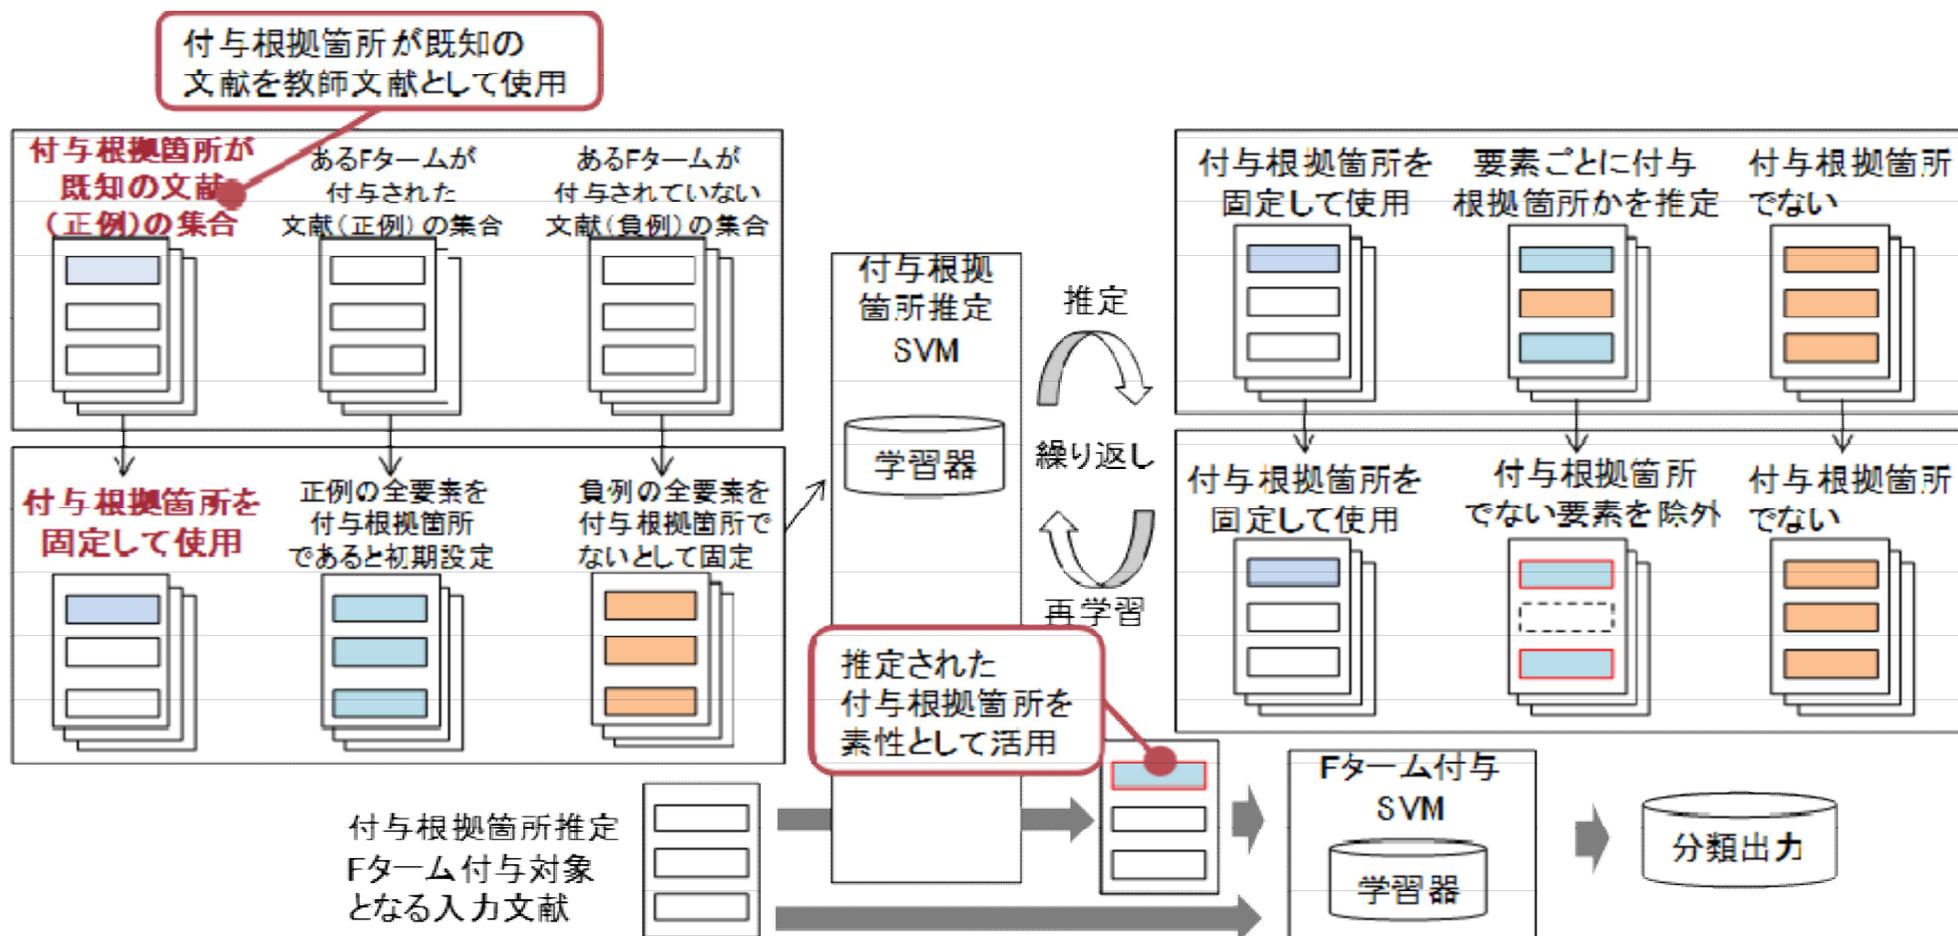
- 付与根拠箇所を学習データとして付与根拠箇所の推定方法を学習するネットワーク
- 付与されたFタームを学習データとしてFターム推定方法を学習するネットワーク



※検証 2 の機械学習モデル : 人手で作成した付与根拠データも機械学習に利用

- mi-SVM+(マルチインスタンスサポートベクターマシン+)

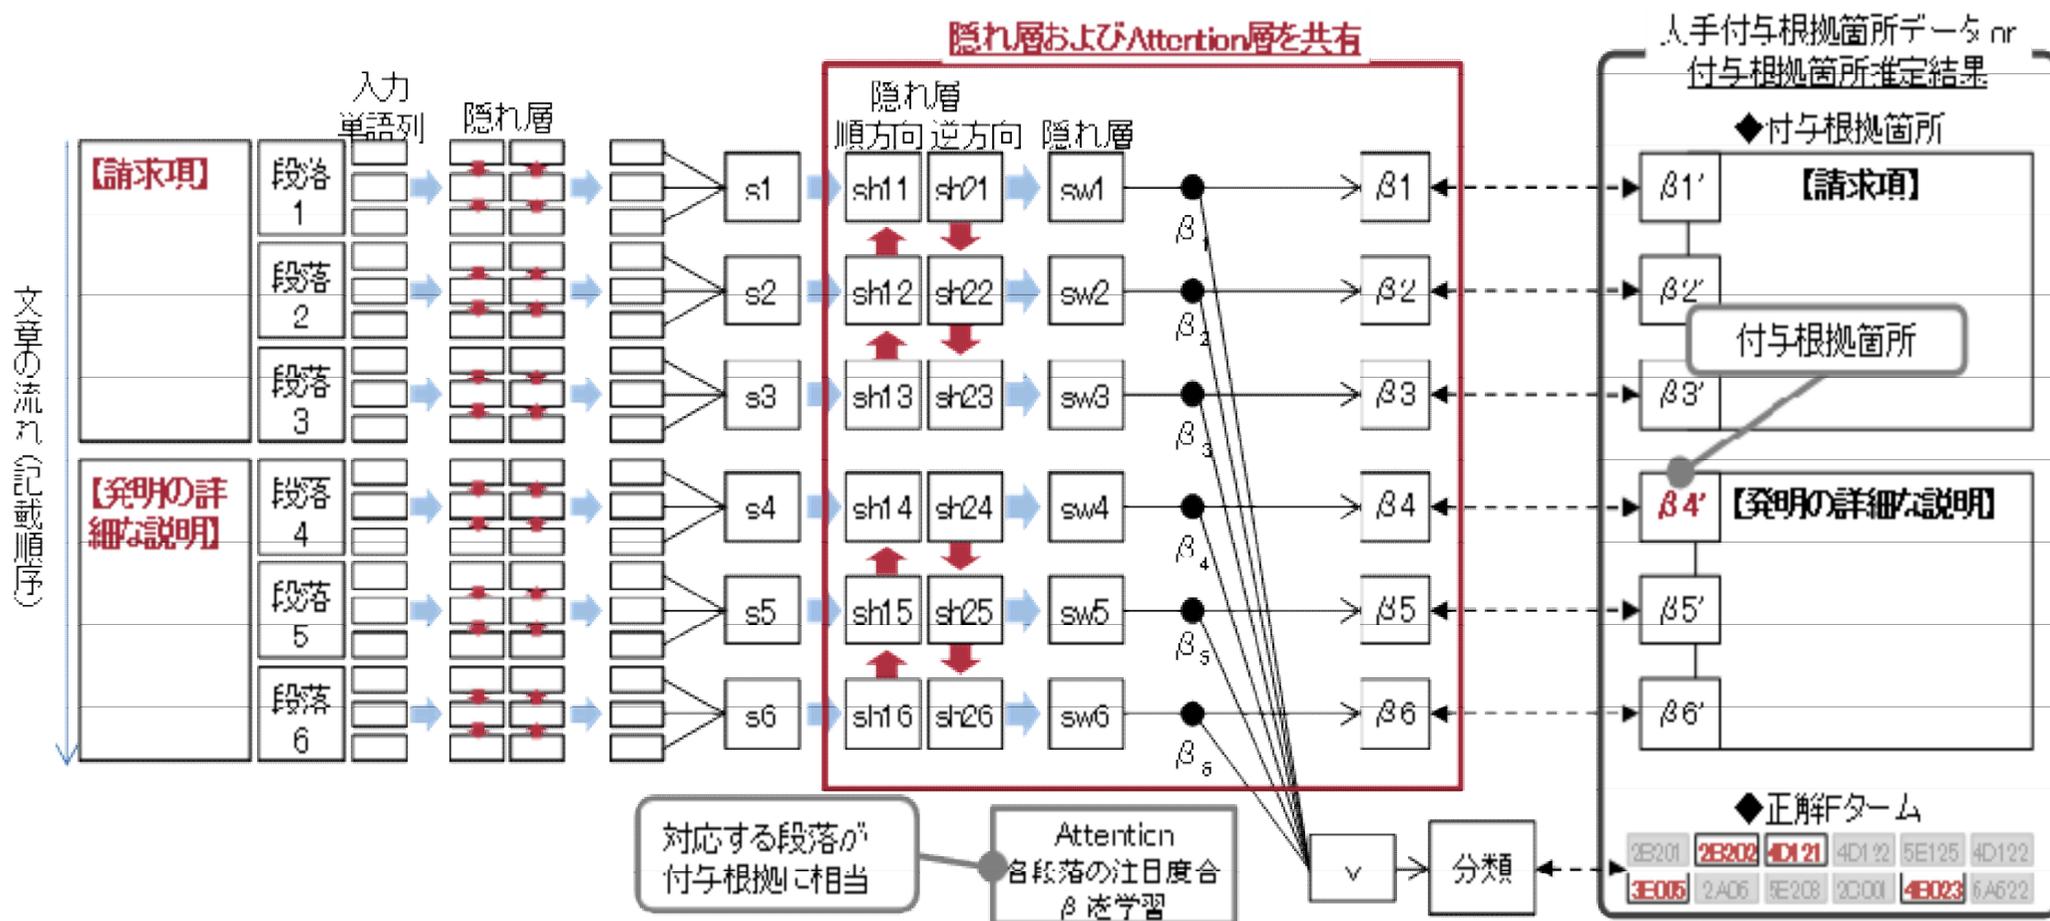
mi-SVMを拡張した機械学習モデル。付与根拠箇所が特定された文献を学習データとして学習に使用可能とすることで、付与根拠箇所やFタームの推定精度の向上が期待される。



※検証 2 の機械学習モデル : 人手で作成した付与根拠データも機械学習に利用

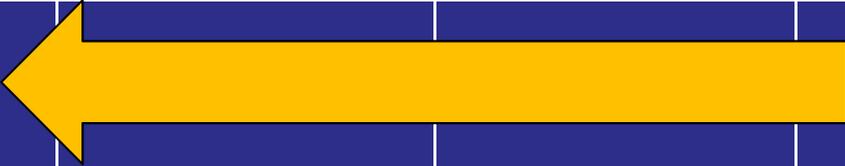
- mt-NAM(マルチタスクニューラルアテンションモデル)

付与根拠箇所推定とFターム付与という二つのタスクを同じモデル上で学習するモデル。
二つのタスクを同じモデル上で学習し、学習の相乗効果により推定精度が向上が期待される。



以下の条件にてFターム付与、及び、付与根拠箇所(特許請求の範囲)の推定精度を評価

- 対象技術分野: 12の技術分野(テーマ)
- 対象Fターム: 技術分野(テーマ)あたり20個のFターム
- 対象文献 : 日本語の公開特許公報
- 精度評価文献: 各テーマ200件の評価文献(正解データ)
- 評価指標: Fターム付与精度(F値)、根拠箇所推定精度(F値)、抽出率

	高			低
Fターム付与精度	NAM+	mt-NAM	SVM	mi-SVM+
根拠箇所推定精度	mt-NAM	NAM	mi-SVM+	-
抽出率 (正解との類似度)	mt-NAM	mi-SVM+	NAM+	-

- 付与根拠箇所の推定精度が最も高いモデル: mt-NAM

- Fターム付与精度が最も高いモデル: NAM+

※いずれもニューラルネットワークを利用しており、また、人手の正解データをAIの学習に利用したモデルであった。

- mt-NAMの付与根拠箇所推定精度が最良だった理由

mt-NAMでは、まずFターム付与を学習し、次にその学習結果を付与根拠箇所に適用してモデルパラメータを調整するが、その際、人手で作成した高精度の付与根拠箇所データを学習に利用したため、この調整が功を奏して付与根拠箇所推定精度が向上したと考えられる。

- NAM+のFターム付与精度が最良だった理由

一方、NAM+では、付与根拠箇所の学習結果をFターム付与に適用するため、Fターム付与精度が向上したと考えられる。

■ 各検証をとおして、さらなる推定精度向上化のための課題やその対策等に関する以下の知見が得られた

• 複合語の分割

本検証では、形態素解析によって特許文献テキストを単語に分割している。その際、分割された単語(名詞、動詞)だけでなく、連続する二つの名詞を一つの複合語(例えば「情報」と「検索」を「情報検索」という一単語とする)として追加することにより、付与根拠箇所推定精度が向上する可能性がある。

• 機械推定の閾値の適切な設定

検証1のNAM及びCNN-NAMの抽出率は、人手で付与した正解付与根拠箇所の抽出率に対し、大幅に高い値となっていた。これは、付与根拠箇所であるかを判定する閾値が固定されており、Fタームによっては絞り込みが適切に機能していなかったことに起因すると考えられる。最良となる閾値を探索することで、抽出率を低くし、より妥当なF値を得られる可能性がある。

• 特許文献の内容・傾向を考慮した再学習

同じ分類(Fターム)でも年代によって技術が変化し、教師文献と最新の特許文献との間に内容の乖離が発生するため、精度が低下していく可能性が高い。そのため、精度の低下を検知する仕組みを構築し、再学習を検討する等の対応が必要。

- 付与根拠箇所が図面に存在する場合への対応

本検証において、付与根拠箇所は特許文献のテキスト部分のみを解析対象としたが、テキスト以外の図面に根拠がある場合も想定される。さらなる精度向上化のためには、テキストに加え、図面も利用できる機械学習モデルを検討する必要がある。

- 教師文献の少ないテーマ・分類における機械学習

教師文献が少ないテーマ及び分類も想定される。そのようなテーマ及び分類では、Fターム及び付与根拠箇所推定精度が低い可能性がある。そのため、類似するテーマの文献も教師データとして、精度向上が可能な転位学習等を活用した方式を検討する必要がある。

- サーバのリソース問題

本検証では、12の技術分野(テーマ)で各技術分野における分類(Fターム)数は20個に限定して調査を行ったが、それでもサーバ11台(GPU88枚)が必要であった。特許の技術分野(テーマ)は、全部で2600個あり、さらにFタームは約36万個に達する。このため、このすべての分類に対応できるようにするためには、単純計算でサーバ76台(GPU6600枚)が必要ということになり非現実的。

サーバの高性能化されるか、少ないサーバでも同程度の精度がでるモデルを開発するかが必要。

特許庁におけるAI活用に向けた取組

<目的>

人工知能(AI)技術の活用により、事務の高度化及び効率化を図り、将来的に、**ユーザーへのサービス向上**や職員の働き方改革につなげる。

<取組概要>

2016年:特許庁業務全体(出願受付～審査まで)の棚卸しを行い、892業務に仕分け。
AIの活用の対象となりうる業務として、15分野・20業務を選定し、その可能性を検討し、今後のアクション・プランを作成・公表。

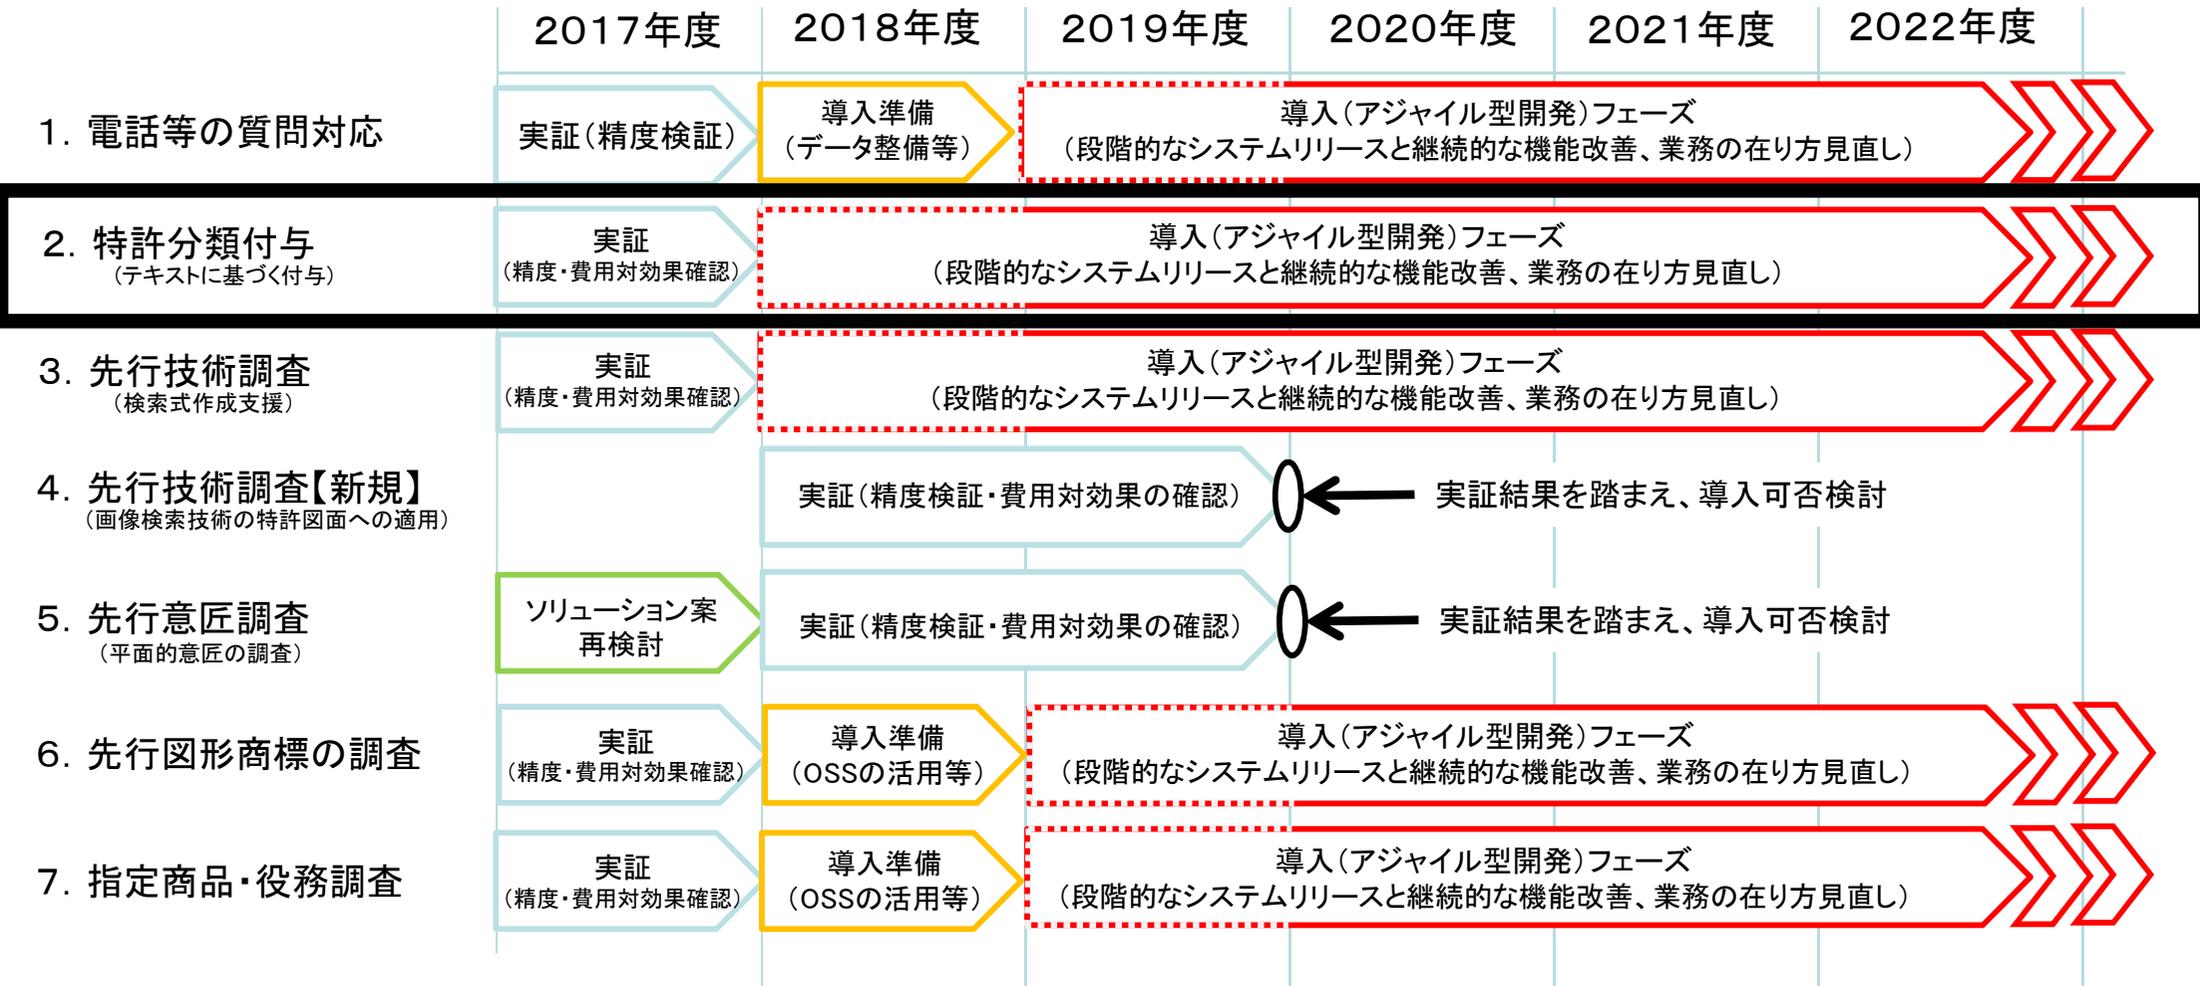
2017年:アクションプランに沿って、6つの個別事業へのサポートにAIが活用できるか実証事業を実施。

<実証事業>

- ◆電話等の質問対応、◆紙出願の電子化、
- ◆先行図形商標調査(イメージサーチ)、◆不明確な商品役務の分類、
- ◆先行技術調査(検索式作成支援)、◆特許分類付与支援

海外他庁との情報交換の活発化

アクション・プラン(平成30年度改定版)

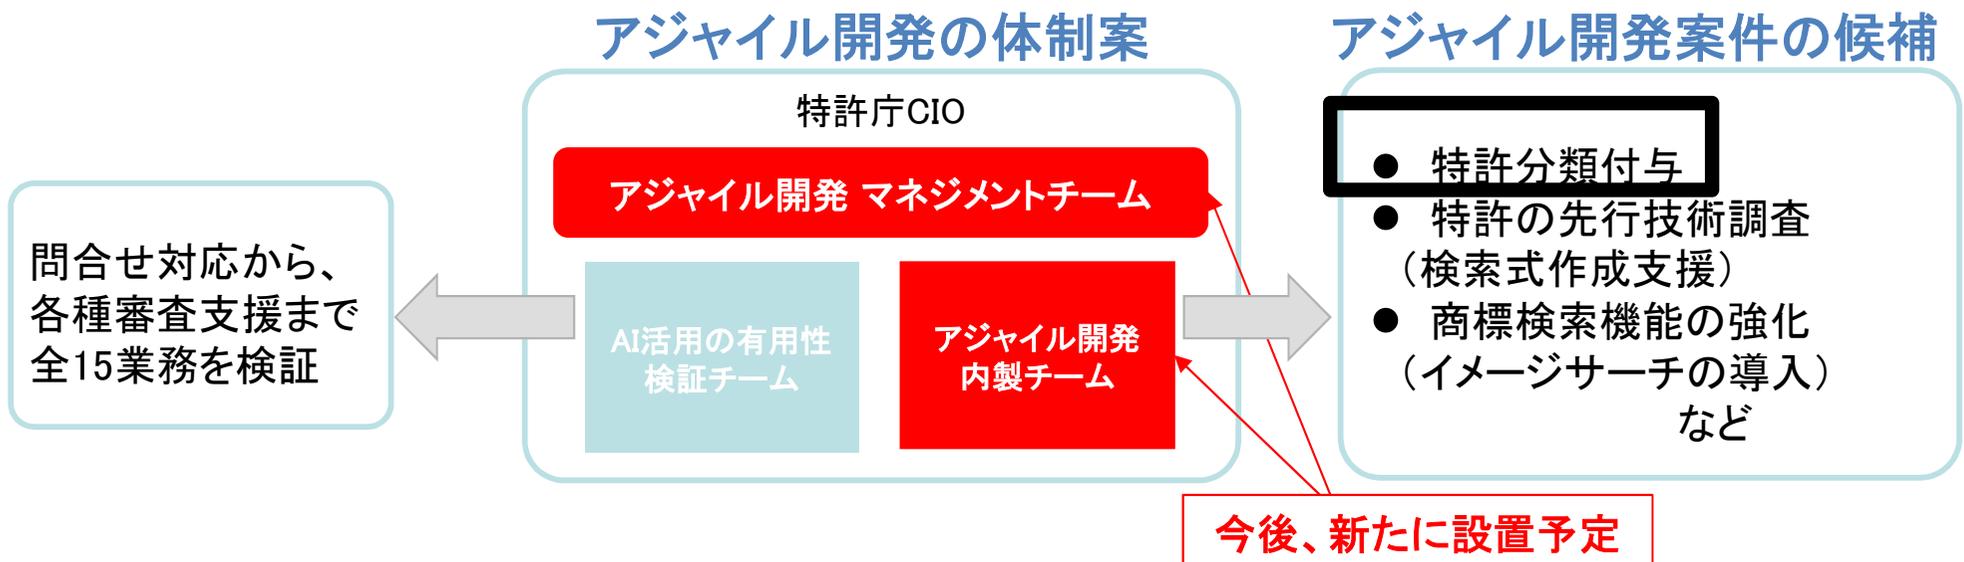


(※)各事業の取組は、大まかな想定であり、実証の進捗状況、関連技術の開発の進展、その他の諸情勢により、変更がありうる。

- 特許庁業務の支援ツールとしてAIを導入し、業務の一層の迅速化・質の向上を図る。
- AI導入は、各国知財庁で取組中。

開発手法

- AIを活用したシステム開発は技術の進展が早いため、短期間でPDCAを回せるアジャイル開発を導入。
(高い信頼性が要求される大規模な基幹システムは、引き続きウォーターフォール開発を実施。)
- AIによる支援ツールは、特許庁自身が責任を持って微調整を続けるため、ブラックボックス化を避ける必要があり、内部人材が自ら開発。



ご清聴ありがとうございました。