



Analytics Design Lab

株式会社NTTデータ数理システム AI活用セミナー

テキストマイニング×AIで賢い特許文書分析を

AIが導く特許文書に潜む特徴の理解と技術戦略の新たな発想

株式会社アナリティクスデザインラボ
代表取締役 野守耕爾

2018年4月5日

会社紹介と自己紹介

人工知能技術を応用したデータ分析の研究開発とビジネスコンサルティングの経験を活かし、
2017年6月にデータ活用コンサルティングの新会社を設立しました

株式会社アナリティクスデザインラボ

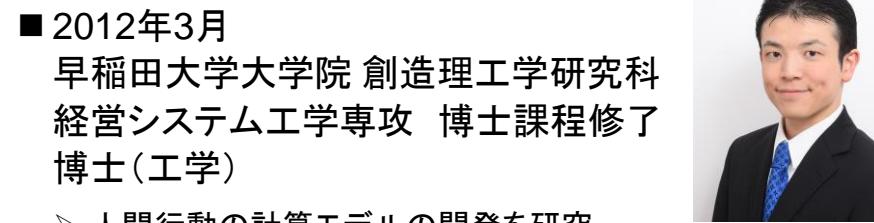
企業におけるデータ活用を支援するコンサルティング会社です。



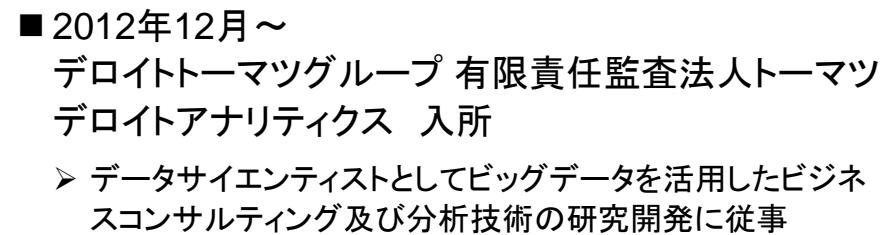
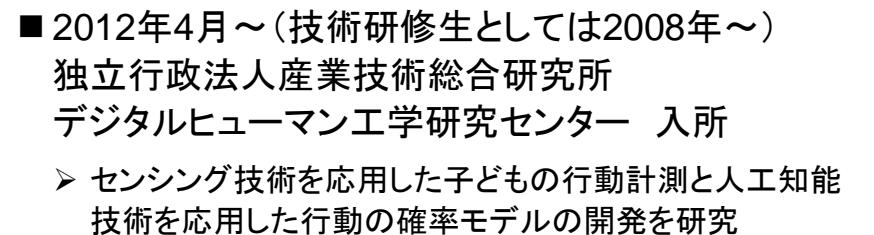
データというスタートから課題の解決というゴールまでをいかにつなげばよいのか、どのようなデータ処理、分析手法、考察、アクションを検討していくべきなのか、というデータ分析を活用するプロセスを企業の抱える課題や思惑・事情などに応じてしっかりとデザインし、それを実行することで企業の課題解決を支援します。

設立	2017年6月1日
事業内容	<ul style="list-style-type: none">● 企業におけるデータ活用のコンサルティング● データ分析技術の研究開発
資本金	5,000,000円
所在地	東京都中野区東中野1-58-8-204

野守 耕爾



➤ 人間行動の計算モデルの開発を研究

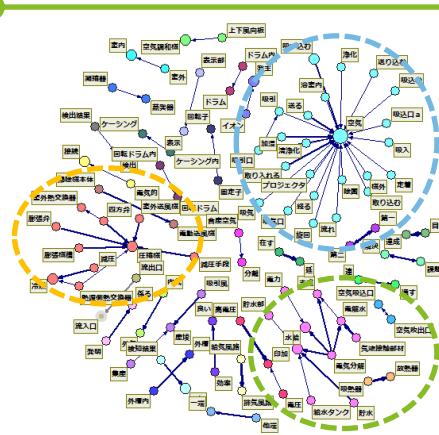


人工知能技術を応用した新たな特許分析アプローチ

これまでの特許分析

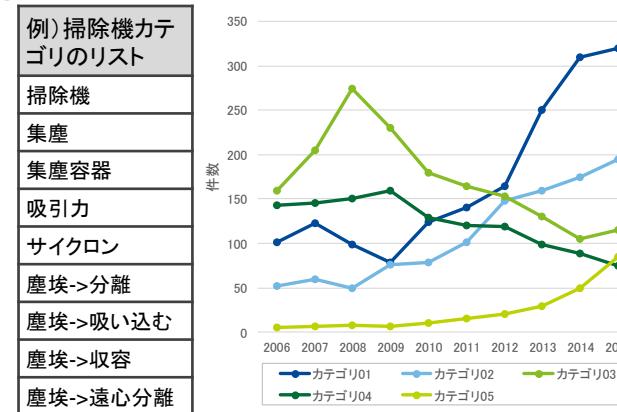
単語をベースに、あるいは手動でグルーピングしたカテゴリをベースに、全体の出現状況、経年変化、出願人の特徴、課題と解決手段の対応関係などを把握する分析がよく行われます

共起ネットワークによる全体像把握



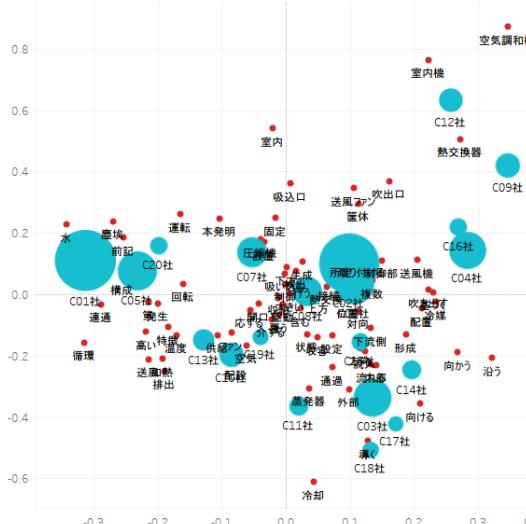
- 単語の共起関係をネットワークで可視化する
 - ネットワークのかたまりを見ながら、全体でどのような話題が形成されているのか考察する

手動設定したカテゴリのトレンド把握



- 抽出した単語を手動でいくつかのカテゴリにグループピングする
 - 各カテゴリの出願年ごとの出現頻度をグラフ化し、トレンドを把握する

コレスポンデンス分析による出願人の特徴把握



- 単語の出現データから共通して現れる特徴的な軸を2つ抽出する
 - その2軸による平面上に単語と出願人を同時にマッピングする
 - 出願人の周辺に配置された単語群から各出願人の特徴を考察する

課題と解決手段のクロス集計による関係把握



- 「要約」の【課題】と【解決手段】それぞれに対して出現単語のカテゴリを設定する
 - 課題と解決手段のカテゴリのクロス集計をして、用途と技術の関連性を考察する

これまでの特許分析の課題と解決技術

複数の人工知能技術を組み合わせることで、特許データを単語ベースではなく、客観的に抽出されるトピックベースで解釈し、そのトピックの統計的な関連性を分析できます

単語ベースの分析では
複雑で考察しにくい

カテゴリの設定が主観的で
作業負荷も大きい

課題と解決手段の統計的な
関係を分析していない

単語を賢くクラスタリングする
人工知能技術

要因関係をモデリングする
人工知能技術

PLSA
確率的潜在意味解析

文脈を考慮した潜在的なトピック
(単語の集合)を抽出する

ベイジアンネットワーク

多様な要因間の確率統計的な
因果関係をモデル化する

PLSAは、データをいくつかの潜在変数で説明するクラスタリング手法です

PLSAの概要

- 行列データの行の要素xと列の要素yの背後にある共通特徴となる潜在クラスzを抽出する手法である
- 元々は文書分類のための手法として開発されている (Hofman, 1999)
- 各文書の出現単語を記録した文書(行) × 単語(列)という高次元(列数の多い)共起行列データに適用することで複数の潜在トピックを抽出し、文書(行) × トピック(列)という低次元データに変換して文書を分類する

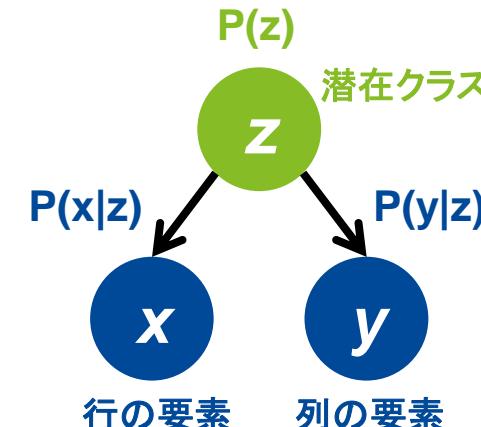
文書ID	単語1	単語2	単語3	...	単語5,014	単語5,015
1	0	0	1		1	0
2	1	0	1		0	1
...						



文書ID	トピック1	トピック2	...	トピック11
1	0.09%	0.03%		0.04%
2	0.01%	0.12%		0.06%
...				

例えば数千列ある高次元のデータでも十数個の潜在トピックで説明することができます

PLSAのグラフィカルモデル



- $P(z)$, $P(x|z)$, $P(y|z)$ の3つの確率が計算される
- 潜在クラスzの数はあらかじめ設定する

※条件付確率 $P(A | B)$
事象Bが起こる条件下で事象Aの起こる確率

xとyの共起確率を潜在クラスzを使って表現する	$P(x, y) = \sum_z P(z)P(x z)P(y z)$
-------------------------	-------------------------------------

PLSAのメリット

行の要素と列の要素を同時にクラスタリングできる

潜在クラスは行の要素と列の要素の2つの軸の変動量に基づいて抽出され、結果も2つの軸の情報から潜在クラスの意味を解釈することができる

ソフトクラスタリングできる

全ての変数が全てのクラスに所属し、その各所属度合いが確率で計算されるため、複数の意味を持つ変数がある場合でも自然と表現できる

複雑な観測情報を分かりやすくかつ忠実に把握するため、PLSAを選択します

階層型 クラスター分析

- 要素間の距離を計算し、距離の近い要素同士を結合してクラスタを構成していく
- 結合の過程が樹形図で表され、結果を見てからクラスタ数を決められる(ボトムアップ的なクラスター分析)
- データ数が多くなると計算が膨大となる

非階層型 クラスター分析 (k-means法など)

- あらかじめクラスタ数を決め、そのクラスタ数に全要素を一回でグルーピングする
- 各クラスタ(の重心)に対して要素の距離を計算し、距離の近い要素で集められたクラスタとなるように分類結果を調整する
- 階層型クラスター分析よりも計算量が抑えられる

特異値分解 LSA (Latent Semantic Analysis)

- $(m \times n)$ の行列を、 $(m \times k), (k \times k), (k \times n)$ に分解する
- m 個のデータと n 個の変数を、 k 個の潜在クラスで表現する(クラス数はあらかじめ設定する)
- 大きな値をとりやすいクラスが残る傾向にあるため、各要素は事前に重み付けする必要がある

PLSA (Probabilistic Latent Semantic Analysis)

- LSAを確率的に処理
- LSAのような事前の重み付けは必要がない
- $P(x,y)$ の確率を、 $P(x|z), P(y|z), P(z)$ に分解する
- 行要素 x と列要素 y を、潜在クラス z で表現する(クラス数はあらかじめ設定する)
- 結果は観測データのみから定義され、新規データはクラスで表現できない(過学習)

LDA (Latent Dirichlet Allocation)

- PLSAの拡張手法
- PLSA(他3つの手法も含め)の過学習の問題に対して、LDAではディレクレ分布を仮定し新規データのクラスを推定できる
- 新規データに対応するため、抽出されるクラスは観測データを忠実に再現するものではなく、クラスの抽象度が高い傾向がある

ハードクラスタリング

- 一つの要素は必ず一つのクラスタに所属する
- 基本的に要素間の距離に基づいて分類を行う
- 列要素の距離に基づいて行要素を分類するか、行要素の距離に基づいて列要素を分類し、行と列どちらか一方を分類する
- 要素数が多くなると要素間の距離が離れていく妥当な結果が得られにくい(次元の呪い)

ソフトクラスタリング(潜在クラス分析、トピックモデル、次元圧縮)

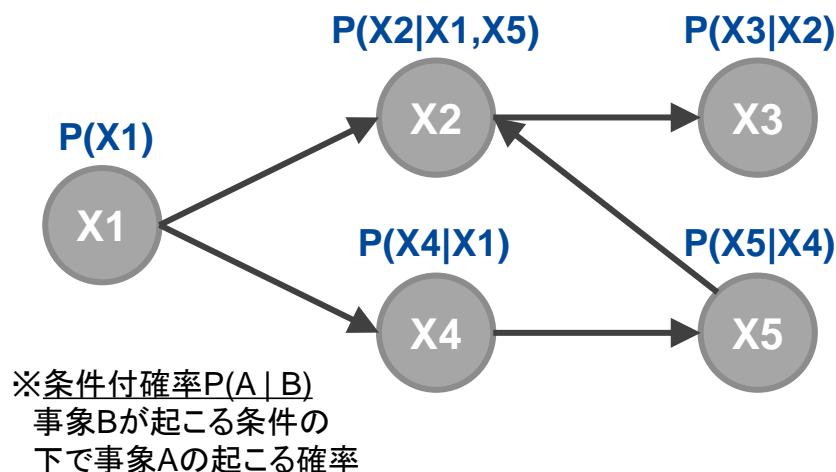
- 一つの要素は全てのクラスに所属し、その所属の重みを計算するため、データが複数の特徴をまたがる場合でも表現できる
- 行の要素と列の要素の背後にある共通する特徴をクラスとして抽出するため、行と列の両方をクラスタリングでき、クラスの持つ情報が多い
- 要素間の距離の近さで分類するのではなく、高次元データの情報をできるだけ保存した形で低次元に変換する次元圧縮手法であるため、要素数が多い複雑なデータにも対応できる

ベイジアンネットワーク

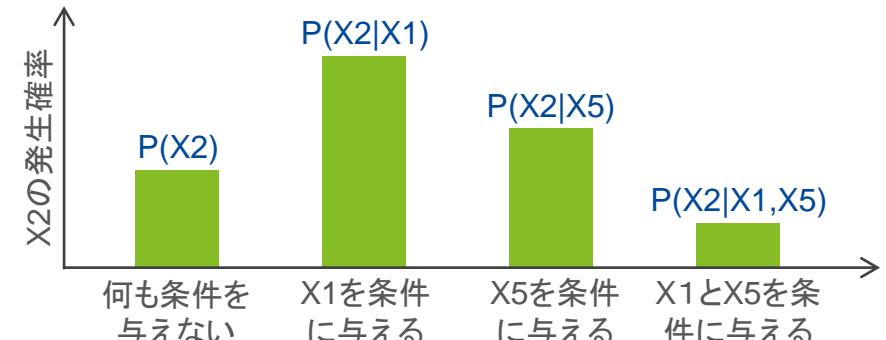
ベイジアンネットワークは、変数間の確率的な因果関係を探索するモデリング手法です

ベイジアンネットワークの概要

- 複数の変数の確率的な因果関係をネットワーク構造で表わし、ある変数の状態を条件として与えたときの他の変数の条件付確率を推論することができる
- 目的変数と説明変数の区別ではなく、様々な方向から変数の確率シミュレーションができる
- 全ての変数は質的変数(カテゴリカル変数)となるため、量的変数の場合は閾値を設けてカテゴリに分割する
- 確率論の非線形処理によるモデル化のため、非線形の関係や交互作用が生じる現象でも記述できる



確率的因果関係と交互作用



- X2の発生確率は、何も条件を与えない時(事前確率)と比べて、X1やX5を条件に与えると確率が上昇する
 \Rightarrow X1やX5はX2の発生に関して"確率的な"因果関係がある
- しかし、X1とX5の両方を条件に与えると、元々の事前確率よりも確率が下がってしまう
 \Rightarrow X1とX5はX2に対して交互作用がある(X1とX5は相性が悪い)

ベイジアンネットワークのメリット

現象を理解して柔軟に
シミュレーションできる

効果を発揮する有用な
条件を発見できる

目的変数、説明変数の区別なく変数の関係をモデル化するので、現象の構造を理解でき、推論変数と条件変数を自由に指定して確率推論できる

ある条件のときにだけ効果が現れるといった交互作用がある場合でも、確率的に意味のある関係としてモデル化することができます

なぜベイジアンネットワークでモデリングか

テキストで記された現象に潜む要因関係を理解するため、ベイジアンネットワークを選択します

ニューラルネットワーク (ディープラーニング)

- ・ 入力(説明変数)と出力(目的変数)の関係(非線形)をモデル化する
- ・ 入力と出力の間に中間層(隠れ層)を設定し、入力情報に重みをつけて出力精度を高める処理を中間層で行う
- ・ 柔軟性が高く複雑な関係もモデル化でき予測精度も高まるが、処理が複雑すぎてモデルの中身がブラックボックス化してしまう

回帰分析・判別分析 (数量化 I類・II類)

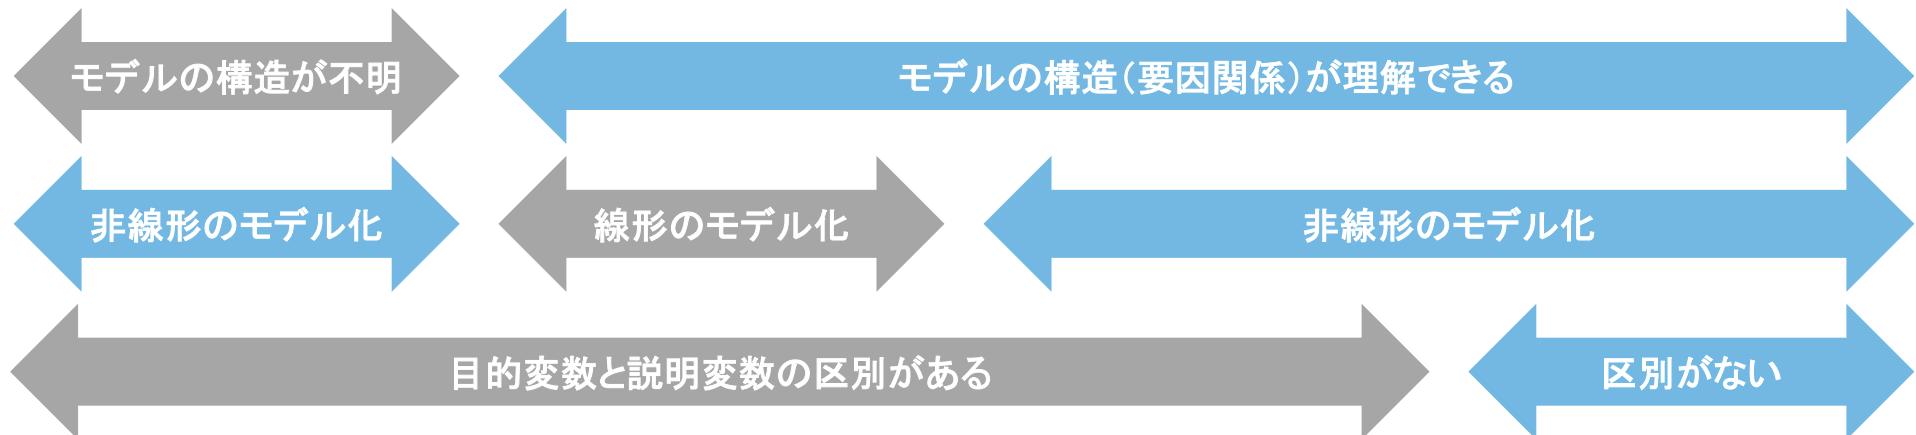
- ・ 目的変数を説明変数の1次結合で定式化する
- ・ 目的変数と説明変数の間に線形関係があるという仮定に基づいている
- ・ 各説明変数の影響は独立しており、複合的な交互作用の影響は表現できない
- ・ 説明変数間で相関が高い場合は解が不安定となり(多重共線性)、変数が多い場合この解消検討の負荷が大きい

決定木

- ・ 目的変数の特徴がよく現れるルールを説明変数とその閾値による分岐で構成する
- ・ ルールがツリー構造で可視化されるため目的変数と各説明変数の関係が分かりやすい
- ・ 目的変数と説明変数の非線形な関係もモデル化でき、複合条件によって効果が変化する交互作用を表現しやすい

ベイジアンネットワーク

- ・ 複数の変数の確率的な因果関係をネットワーク構造でモデル化する
- ・ 目的変数と説明変数の区別がないため、それぞれの変数が互いにどのような関係をもってそのデータの現象を構成しているのか理解できる
- ・ 変数間の関係は条件付確率で計算され、複合条件によって効果が変化する交互作用も表現できる



膨大なテキストデータをトピックに変換して解釈を容易にし、テキスト情報内に潜む要因関係をモデル化して、ビジネスアクションに有用な特徴を把握可能にします

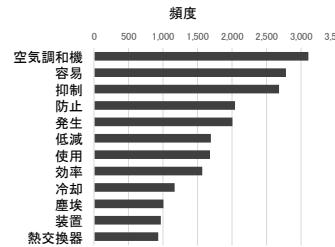
Nomolytics: Narrative Orchestration Modeling Analytics

テキストマイニング

文章に含まれる単語を抽出し、その出現頻度を集計する

単語抽出

Text Mining Studio



PLSA 確率的潜在意味解析

単語が出現する文脈を学習し、膨大な単語を複数のトピックにまとめる

トピック抽出

Visual Mining Studio

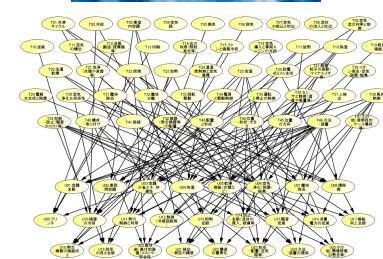


ベイジアンネットワーク

トピックやその他属性情報など、テキスト情報内の要因関係をモデル化する

モデリング

BayoLink



膨大なテキストデータを人間が理解しやすい形に整理できる

テキスト情報内に潜む複雑な要因関係を構造化できる

条件を変化させたときの結果の挙動をシミュレーションできる

ある事象の発生確率をコントロールする条件を発見できる

特許要約の【課題】と【解決手段】から用途と技術のトピックを抽出し、トピックのトレンド分析や出願人の特徴分析、また用途と技術の関係分析によって技術戦略を検討します

A. 用途と技術のトピック抽出

データの抽出



- 特許文書の要約文の「課題」と「解決手段」のテキストデータを抽出する
- 「課題」からは用途トピックを、「解決手段」からは技術トピックを抽出する

テキストマイニング

用途トピックの抽出

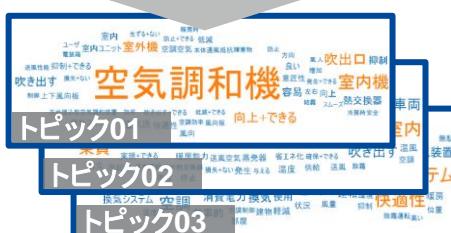
テキストマイニングを行して単語と係り受け表現を抽出する

単語	品詞	頻度
空気調和機	名詞	3,106
空気	名詞	2,846
容易	名詞	2,790
抑制	名詞	2,687
...

「単語 × 係り受け」の共起行列を作成し、これにPLSAを適用してトピックを抽出する

PLSA

単語	係り受け			
	機 空 提 供	空 氣 調 和	効 率 良 い	提 供 掃 除 機
空気調和機	1,578	100	1	
空気	85	144	45	
容易	190	105	67	



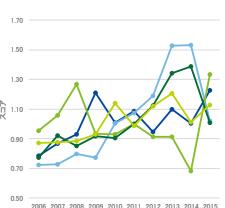
B. トピックの特徴集計

全特許データに各トピックのスコア(該当度)を計算する

ID	出願年	出願人	用途トピック1	用途トピック2				
			用途トピック1	用途トピック2				
1	2014	A社	2.1	0.6	...	1.5	5.0	...
2	2013	B社	0.3	3.4	...	4.6	0.9	...
3	2011	C社	4.8	2.2	...	2.7	1.1	...
n

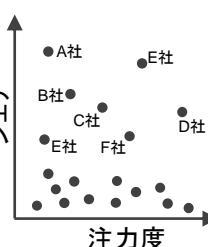
出願年集計

トピックスコアを出願年で集計してトピックのトレンドを把握する



出願人集計

トピックスコアを出願人で集計して、各トピックにおける出願人の特徴を把握する



用途トピックと技術トピックの統計的な関係性をベイジアンネットワークでモデル化する

ベイジアンネットワーク

技術トピック



用途トピック



用途⇒技術

自社で検討中の用途に対してその解決技術の候補を把握し、そのうち自社で想定していない用途を確認し、その関連する特許文書を探索することで、自社技術の新規用途開発戦略や提携戦略を検討する

技術⇒用途

Nomolyticsを適用した特許分析事例

Nomolyticsを適用した特許分析事例

分析データ

「風」「空気」に関する10年分の特許データ30,039件を分析します

データの抽出条件と抽出結果

■ 対象

- 公開特許公報

■ キーワード

- 要約と請求項に「風」と「空気」を含む

■ 出願年

- 2006年～2015年

■ 抽出方法

- PatentSQUAREを使用

■ 抽出結果

- 30,039件



分析データの加工

■ 要約文の【課題】と【解決手段】に記載されている文章をそれぞれ抽出する

- このような書式で記載されていないものは要約文をそのまま使用する

■ 出願人情報は名寄せをし、グループ会社などは統一する

【要約】【課題】ユーザーの快適性を維持しつつ、省エネ運転を行なうことができる空気調和機を提供すること。【解決手段】本発明の空気調和機は、室内温度を検出する室内温度検出手段と、人体の活動量を検出する人体検出手段と、基準室内設定温度を設定するリモコン装置30とを備え、室内温度が基準室内設定温度となるように空調制御を行う空気調和機であって、人体検出手段で検出する活動量が所定の活動量以内であるときは、室内温度が、基準室内設定温度を補正した補正室内設定温度となるように空調を行い、補正室内設定温度よりも低い状態を継続すると、圧縮機を停止させ、圧縮機の復帰は、基準室内設定温度に基づいて行う。

Nomolyticsを適用した特許分析事例

トピック抽出

トピック抽出のアプローチ

テキストマイニングで単語と係り受け表現を抽出し、単語×係り受けで構成される共起行列にPLSAを適用することで単語と係り受けの出現の背後にある潜在トピックを抽出します



【課題】と【解決手段】の文章に含まれる単語と係り受けを抽出する

単語	品詞	頻度
空気調和機	名詞	3,106
空気	名詞	2,846
容易	名詞	2,790
抑制	名詞	2,687
良い	形容詞	2,481
向上	名詞	2,328
防止	名詞	2,047
発生	名詞	2,005
...

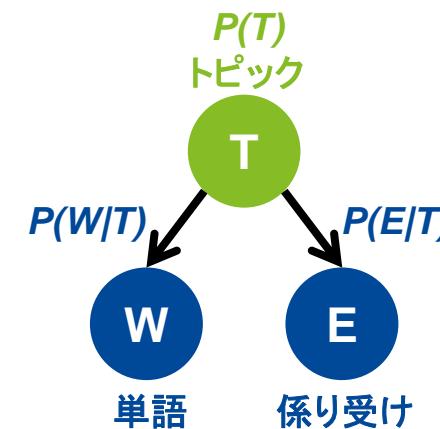
係り受け表現	頻度
空気調和機⇒提供	1,575
効率⇒良い	1,325
車両用空調装置⇒提供	578
掃除機-提供	545
容易-構成	539
画像形成装置-提供	334
抑制-提供	296
向上-図る	279
...	...

抽出した単語と係り受け表現に基づいて、「単語 × 係り受け表現」の共起行列(文章単位で同時に出現する頻度のクロス集計表)を作成する

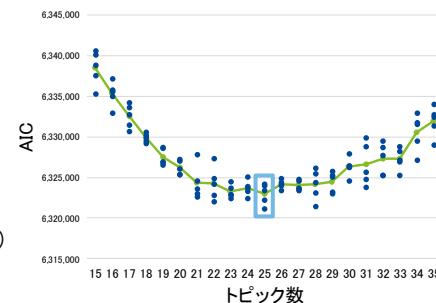
係り受け表現						
	空気調和機⇒提供	効率⇒良い	車両用空調装置⇒提供	掃除機-提供	：	
空気調和機	1578	100	4	1		
空気	85	144	45	50		
容易	100	105	51	67		
抑制	142	95	64	63		
...						

共起行列の構成(それぞれ頻度10件以上を対象)
課題: 単語(3,256語) × 係り受け(2,084表現)
解決手段: 単語(5,187語) × 係り受け(7,174表現)

共起行列にPLSAを適用する



トピック数を幅を持たせて設定し、各トピック数に対してPLSAを初期値を変えて5回ずつ実行して情報量基準AICを計算し、AIC最小の解を採用する



各トピックについて以下の3つの確率が計算される

- ① $P(T)$
トピックの存在確率
- ② $P(W|T)$
トピックにおける単語の所属確率
- ③ $P(E|T)$
トピックにおける係り受けの所属確率

トピックにおける $P(W|T)$ と $P(E|T)$ からトピックの意味を解釈する

U04	
P(U)=2.6%	
P(W U)	単語
5.5%	加湿装置
6.8%	加湿装置-提供
3.7%	水
3.1%	加湿器-提供
3.3%	供給
2.4%	ミスト発生装置-提供
1.9%	水-供給
2.3%	カビ
1.7%	細菌-繁殖
2.1%	加湿器
1.5%	加湿-行う
2.1%	発生
2.0%	繁殖
1.9%	ミスト
1.7%	加湿性能
1.5%	ミスト発生装置
1.4%	細菌
1.3%	室内
1.3%	繁殖-抑制
1.2%	十分-量
1.2%	カビ-発生
1.2%	効率-良い
1.2%	加湿機能付空気清浄機-提供
1.3%	ミスト-噴霧
1.3%	十分-量
1.2%	効率-良い
1.2%	空気調和機-提供
1.1%	加湿-加湿装置
1.1%	浴室
1.1%	空気-加湿
...	...

用途トピック25個の一覧

【課題】の文章からは、空調や加湿、空気清浄、掃除機、プリンタ、機器冷却、騒音や消費電力の低減、構造の簡素化などの用途が25個抽出されました

U01.空調全般



U02.車両用空調



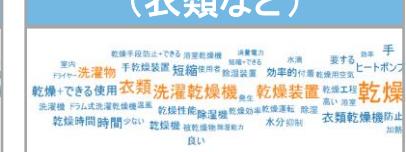
U03.空調の省エネ、快適性



U04加湿



U05.乾燥機能(衣類など)



U06.空気浄化(除菌・消臭)



U07.塵埃除去



U08.掃除機



U09.プリンタ



U11.熱の制御と利用



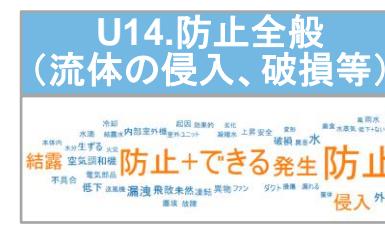
U12.制御(冷媒回路等)



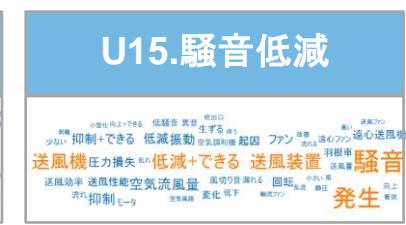
U13.抑制全般



U14.防止全般(流体の侵入、破損等)



U15.騒音低減



U16.消費電力の低減



U17.機能向上全般



U18.熱交換器の機能向上



U19.効率の良さ全般



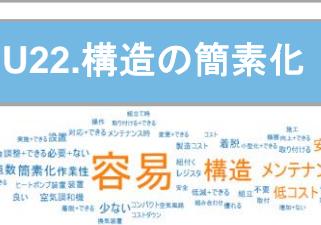
U20.価値(コストや安全性など)



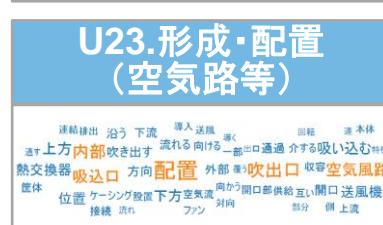
U21.検出・測定の精度



U22.構造の簡素化



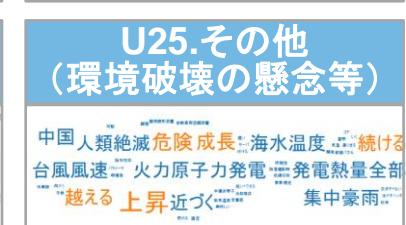
U23.形成・配置(空気路等)



U24.方法・装置の提供



U25.その他(環境破壊の懸念等)



※文字の大きさはトピックに対する関係の強さを表現している
(上位5つの単語を赤色で表示している)

Nomolyticsを適用した特許分析事例

トピックのスコアリング

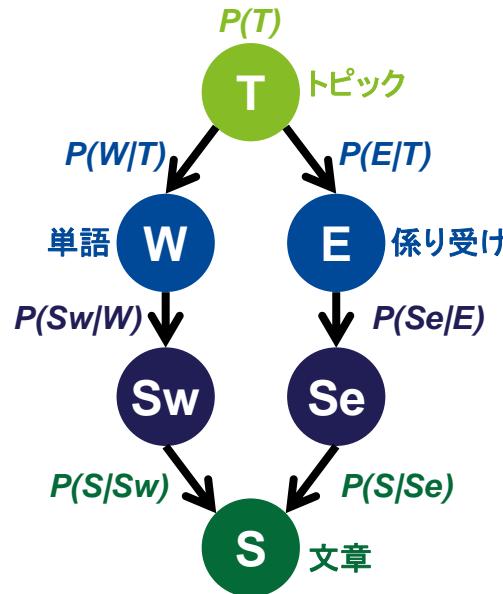
トピックのスコアリング

文章単位に各トピックのスコア(該当度)を計算し、それを特許ID単位に集約し、最終的には閾値を設定して{0:該当無,1:該当有}のデータに変換します

文章単位
のスコア

$$\frac{P(S|T)}{P(S)}$$

- リフト値(事後確率 ÷ 事前確率)
- トピックを条件とすることで文章の発生確率が何倍になるのかを示す



文章を単語で定義される文章Swと係り受けで定義される文章Seを設定し、それぞれトピックとの関係を計算し、最終的にそれらを一つに統合する

単語 W_i で定義される文章 Sw_h

$$Sw_h = \{W_1, W_2, \dots, W_i\}$$

トピック T_k を条件とした文章 Sw_h の出現確率

$$P(Sw_h|T_k) = \sum_i P(Sw_h|W_i)P(W_i|T_k)$$

単語 W_i が出現する中で文章 Sw_h が出現する確率
(W_i の出現文章数の逆数)

$$P(Sw_h|W_i) = 1/n(W_i)$$

係り受け E_j で定義される文章 Se_h

$$Se_h = \{E_1, E_2, \dots, E_j\}$$

トピック T_k を条件とした文章 Se_h の出現確率

$$P(Se_h|T_k) = \sum_j P(Se_h|E_j)P(E_j|T_k)$$

係り受け E_j が出現する中で文章 Se_h が出現する確率
(E_j の出現文章数の逆数)

$$P(Se_h|E_j) = 1/n(E_j)$$

トピック T_k を条件とした文章 S_h の出現確率

※ $P(S_h|Sw_h)$ と $P(S_h|Se_h)$ はともに1/2とする

$$P(S_h|T_k) = P(S_h|Sw_h)P(Sw_h|T_k) + P(S_h|Se_h)P(Se_h|T_k)$$

文章 S_h の出現確率

$$P(S_h) = \sum_k P(S_h|T_k)P(T_k)$$

トピックスコア算出プロセス

①文章ごとにスコアを計算

特許ID	文章ID	T01	T02	T03	...	T47
1	1	3.1	0.9	2.0		1.1
1	2	1.4	0.2	5.5		2.4
2	1	0.8	5.8	1.3		0.9
2	2	1.2	3.2	1.7		1.0
2	3	0.6	1.8	2.6		3.6
...						

②特許IDごとに文章スコアを集約

※最大値を採用する

特許ID	T01	T02	T03	...	T47
1	3.1	0.9	5.5		2.4
2	1.2	5.8	2.6		3.6
...					

③閾値を設定してフラグに変換する

※閾値は3に設定する

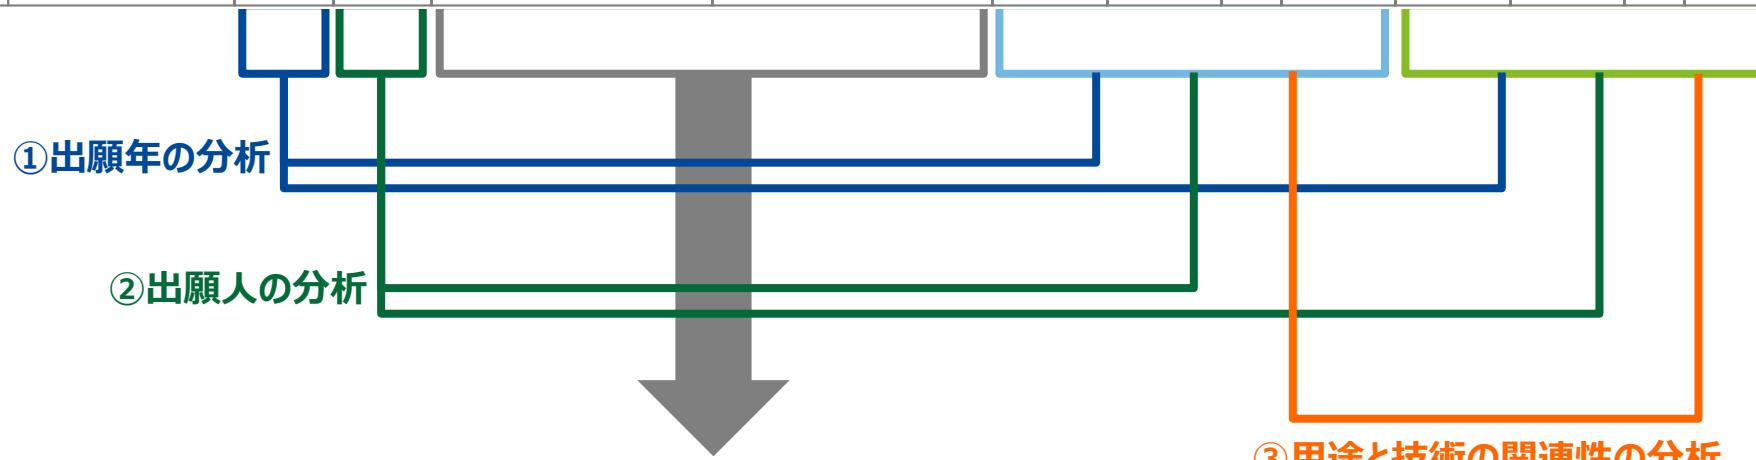
特許ID	T01	T02	T03	...	T47
1	1	0	1		0
2	0	1	0		1
...					

トピックのフラグデータの作成

全特許データに対して各トピックのスコア(該当有無)を計算することで、トピックをベースとした様々な分析を実行することができます

トピックのスコア(フラグ情報)を紐づけた特許データ

特許ID	出願番号	出願年	出願人	要約文		用途 トピック U01	用途 トピック U02	…	用途 トピック U25	技術 トピック T01	技術 トピック T02	…	技術 トピック T47
				【課題】	【解決手段】								
1	特願2006-XXXX	2006	A社	空気調和機の高外気吸気口から導入された	吸気口から導入された	1	0		0	0	1		0
2	特願2009-XXXX	2009	B社	短時間で除霜を行うこと	着霜検出手段が室外	0	1		0	1	0		0
3	特願2011-XXXX	2011	C社	乾燥運転が中断されが	通風路を通して回転構	0	0		1	1	0		0
4	特願2013-XXXX	2013	D社	ウインドシールドの防	車両用空調装置の空	0	1		0	0	1		1
…	…	…	…			…	…	…	…	…	…	…	…
30039	特願2012-XXXX	2012	Z社	プリ空調時に、除菌ま	冷暖房空調ユニットは	0	1		0	1	1		0



トピックをベースにした分析により読むべき
特許文書を効率的に絞り込むことができる

Nomolyticsを適用した特許分析事例

①出願年×トピックによるトレンド分析

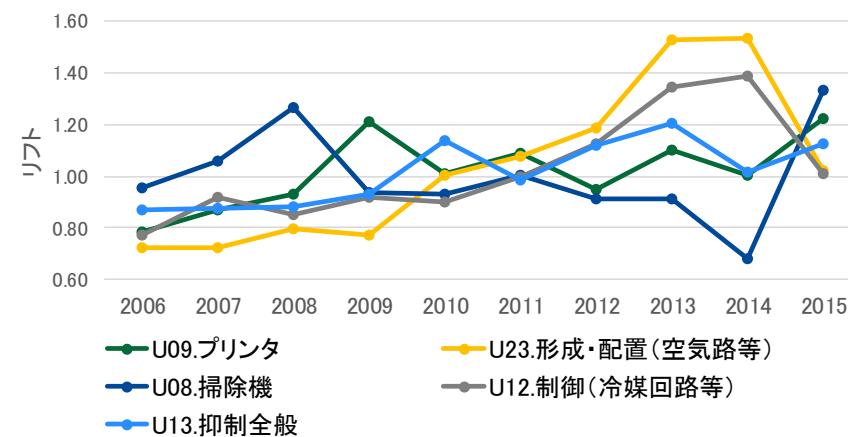
【分析目的】

用途や技術のトレンドを把握し、有望なニーズやシーズを探り、
今後の技術開発戦略を検討する

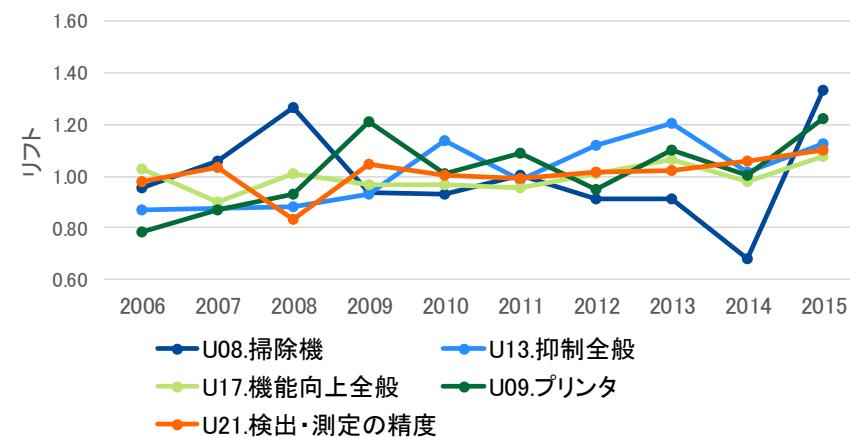
用途トピックの上昇トレンド

近年は掃除機や空気浄化、塵埃除去、プリンタに関する用途が上昇しています

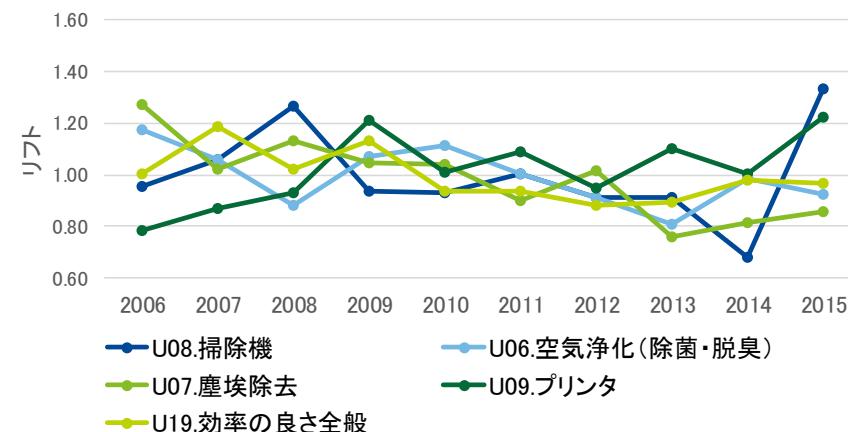
2006年からの上昇率 best5



2011年からの上昇率 best5



2013年からの上昇率 best5



集計の仕方

- リフト値を出願年・トピックごとに集計

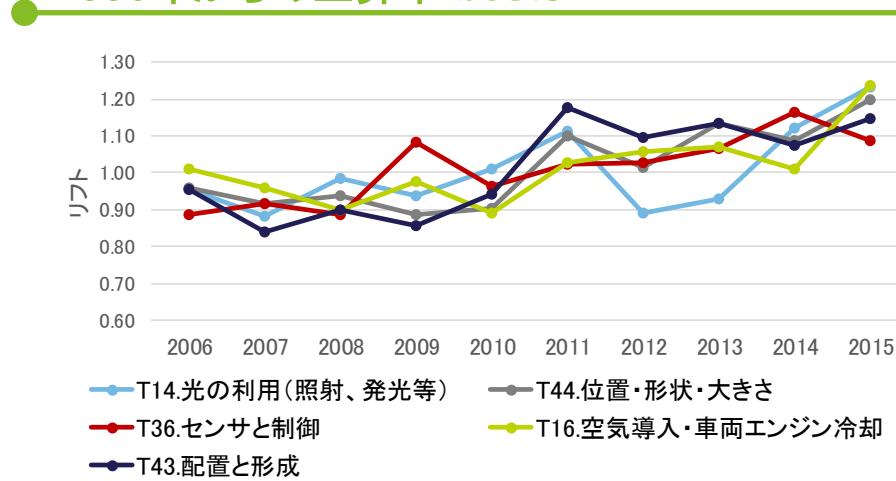
$$\frac{P(\text{出願年} \mid \text{トピック} Ux=1)}{P(\text{出願年})}$$

- その出願年の出願件数割合を平均(=1)として標準化した値

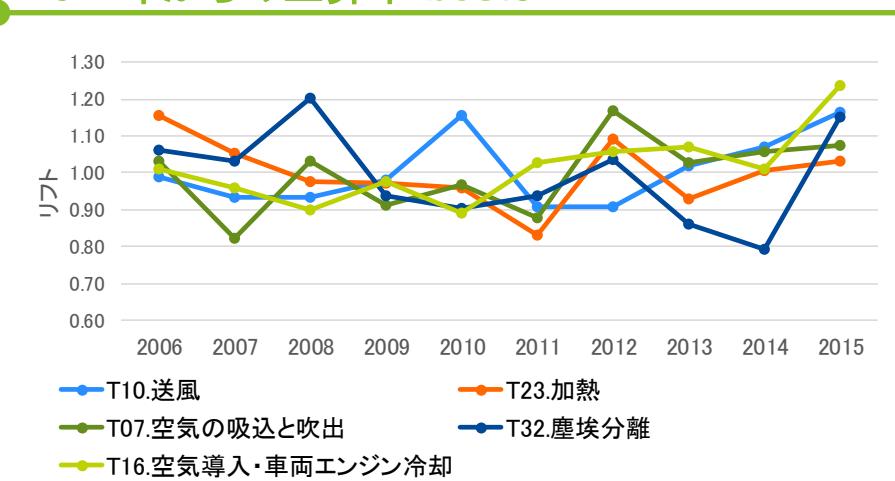
技術トピックの上昇トレンド

近年は塵埃分離や車両エンジンの冷却に関する技術が、長期的にはプロジェクタなどの光の利用に関する技術が上昇しています

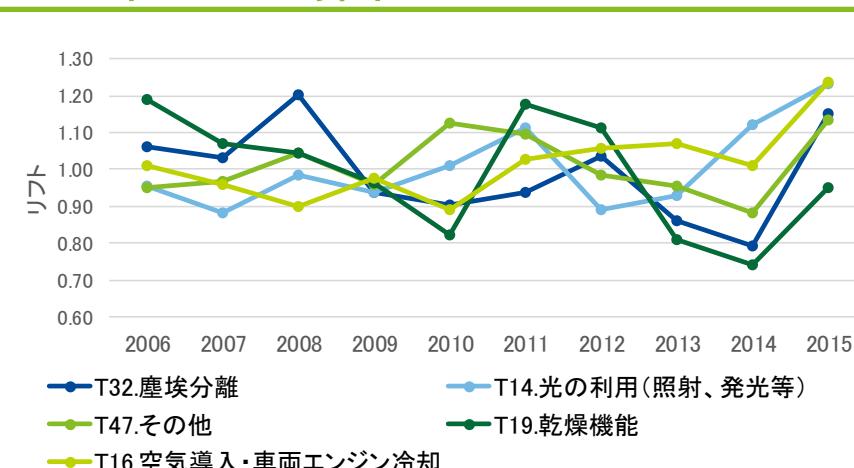
2006年からの上昇率 best5



2011年からの上昇率 best5



2013年からの上昇率 best5



集計の仕方

- リフト値を出願年・トピックごとに集計

$$\frac{P(\text{出願年} \mid \text{トピック} T_x=1)}{P(\text{出願年})}$$

- その出願年の出願件数割合を平均(=1)として標準化した値

Nomolyticsを適用した特許分析事例

②出願人 × トピックによる競合分析

【分析目的】

各出願人の動向を把握し、自社の技術開発戦略や差別化戦略、
他社との提携戦略、自社技術の売却先などを検討する

出願人×トピックの指標値

注力度とシェアの2つの軸で各トピックにおける出願人の特徴を把握します

注力度(関心度)

- 出願人Xの出願特許の中で、どれくらいの割合がそのトピックTに該当するものか
- 出願人がどれくらいそのトピックに注力しているのかを示しており、高い技術を保有している可能性がある

$$P(\text{トピック} T = 1 | \text{出願人} X = 1)$$

シェア

- トピックTが該当する特許の中で、どれくらいの割合がその出願人Xの出願によるものか
- トピックのなかでどれくらいその出願人が占めているのかを示しており、技術市場のシェアともいえる

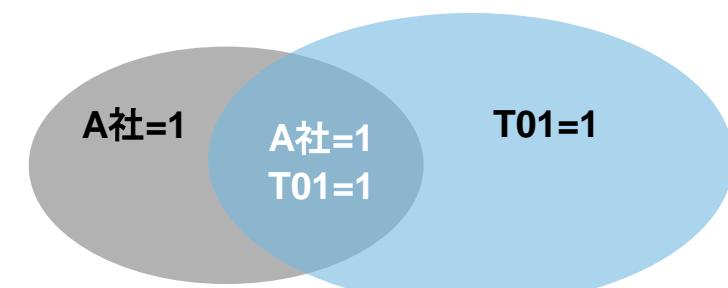
$$P(\text{出願人} X = 1 | \text{トピック} T = 1)$$

集計対象

- 名寄済みの出願人情報のうち、出願件数上位26社を集計対象とする

集計データと集計イメージ

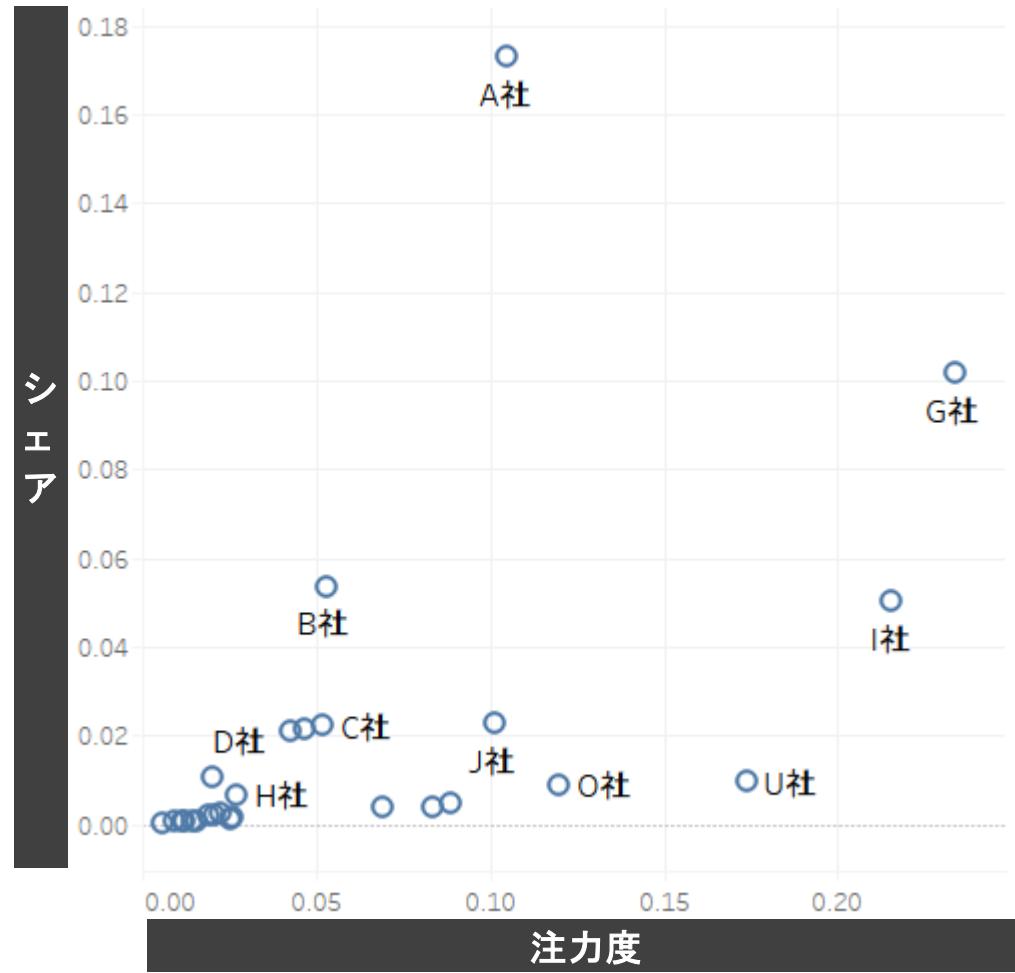
特許ID	出願人A社	出願人B社	出願人C社	...	トピックT01	トピックT02	トピックT03	...
1	1	0	0		1	0	0	
2	1	0	0		0	0	1	
3	1	0	0		1	0	0	
4	1	0	0		1	0	0	
5	1	0	0		1	0	0	
6	0	1	0		0	1	0	
7	0	1	0		0	1	1	
8	0	1	0		1	1	0	
9	0	1	1		0	0	0	
10	0	0	1		0	1	0	
...	



用途「U06.空気浄化」の各出願人のポジショニング

空気浄化に関する用途は、1社のシェアがとても高いものの注力度は高くなく、他に注力度のとても高い企業が存在するため、これらの企業と連携することで一強の存在になります

注力度とシェアの散布図



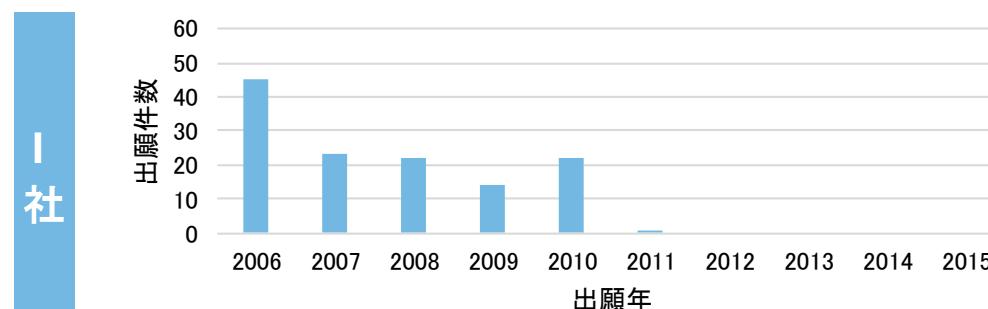
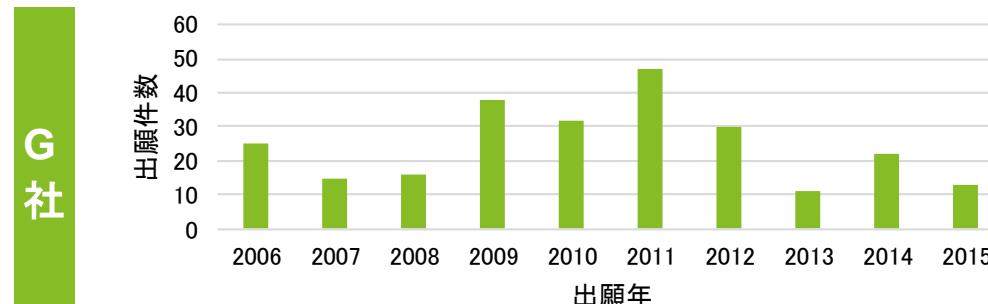
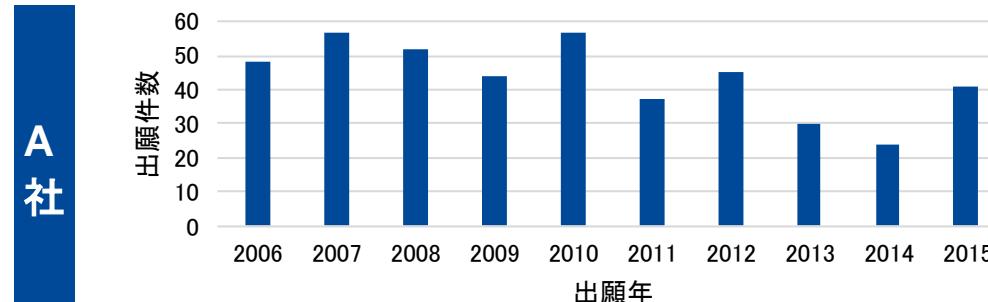
考察と戦略の検討

- A社は、シェアでは他社を大きく突き放しているが、注力度はそれほど高くはなく、A社にとって特に関心は強くない可能性がある
- G社とI社は注力度が高く、この用途に関心が強い出願人であり、この用途を実現するうえで高い技術を保有している可能性がある
- シェアではA社とのギャップはあるもののG社は第2位、I社は第4位のシェアがある
- A社は注力度の高いG社やI社と連携することで、高シェア高注力度のポジションを確立し、この用途において一強の存在となりうる
- G社とI社は、巨大なA社の関心が高くなかった間に独自の技術開発を進めることで、高い技術力による差別化を図ることができる
- あるいはG社とI社は、自社の独自技術を巨大なA社にライセンスや売却して収益化することも考えられる

用途「U06.空気浄化」の各出願人の出願トレンド

注力度は高くないと思われたシェア1位のA社は、近年は出願件数を伸ばしており、今後積極的な開発や提携も考えられ、一方注力度の高いと思われたG社は近年出願が減っています

注目企業の出願件数のトレンド



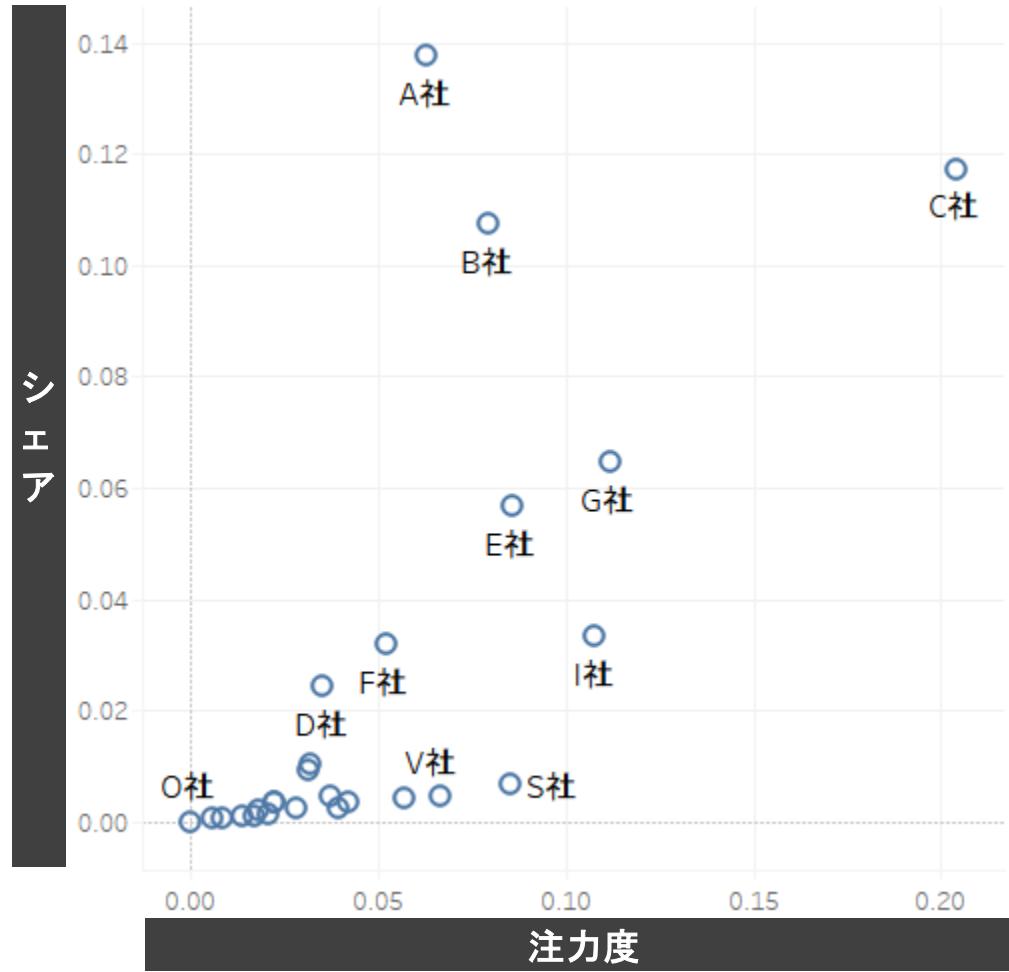
考察と戦略の検討

- シェア第1位のA社は、全体では注力度は高くなかったが、近年は出願件数を伸ばしており、この用途において関心が高まっている可能性がある
 - 今後積極的な技術開発や提携が考えられる
- 注力度第1位、シェア第2位のG社は、以前はこの用途の技術に注力して開発をしていた可能性があるが、近年は出願件数は減っており、現在はこの用途の関心は低くなっている可能性がある
 - 今後この用途に注力しないのであれば、これまで培ってきた技術を他社にライセンスや売却して収益化するということも考えられる
- 注力度第2位、シェア第4位のI社は、2012年以降の出願件数はなく、この用途の技術開発を終了している、あるいは会社が存在しない可能性がある

技術「T32.塵埃分離」の各出願人のポジショニング

塵埃分離に関する技術は、1社の注力度が高いものの、他にもある程度のシェア・注力度を保有する企業が何社か存在するため、今後連携などの動きも考えられる領域と思われます

注力度とシェアの散布図



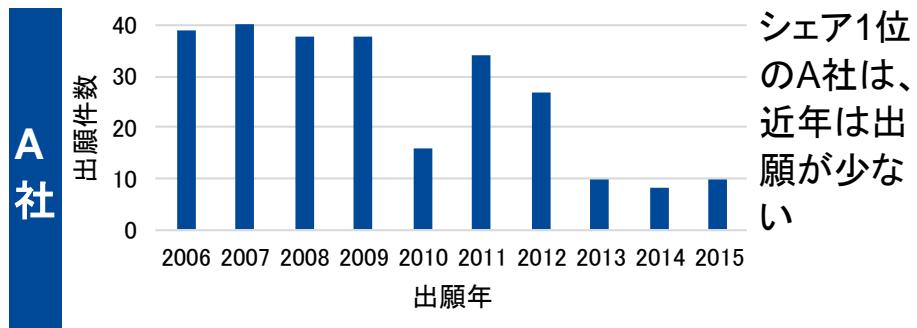
考察と戦略の検討

- C社は、高めのシェアを獲得しつつ、他社と比べて注力度がとても高く、高い技術力を保有していると考えられ、今後はよりシェアを伸ばすことで高シェア高注力度のポジションを確立することができると考えられる
- A社とB社は、シェアは高いがまだC社に注力度で劣っているので、例えば規模は中程度だが注力度は比較的高く、技術力があると思われるE社、G社、I社などと連携することで、C社の上のポジションを狙うことができる可能性がある

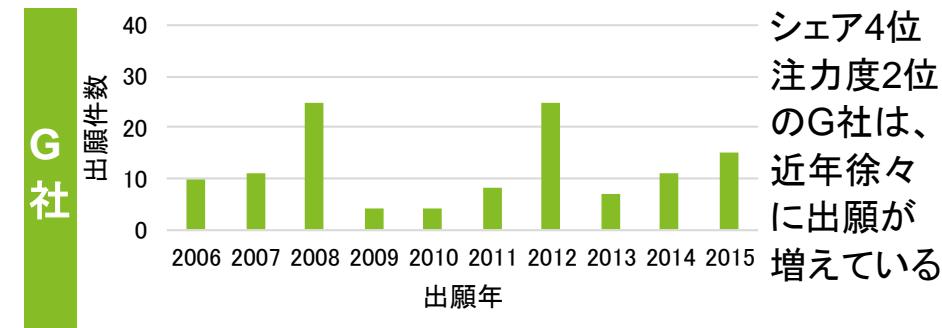
技術「T32.塵埃分離」の各出願人の出願トレンド

注力度1位のC社は直近で出願が急増し、高シェアのA社とB社の近年の出願動向は、A社は減少ですがB社は増加で、またシェア4位のG社も出願を伸ばしており、今後に要注目です

注目企業の出願件数のトレンド



注目企業の出願件数のトレンド



Nomolyticsを適用した特許分析事例

③用途トピック × 技術トピックの関係分析

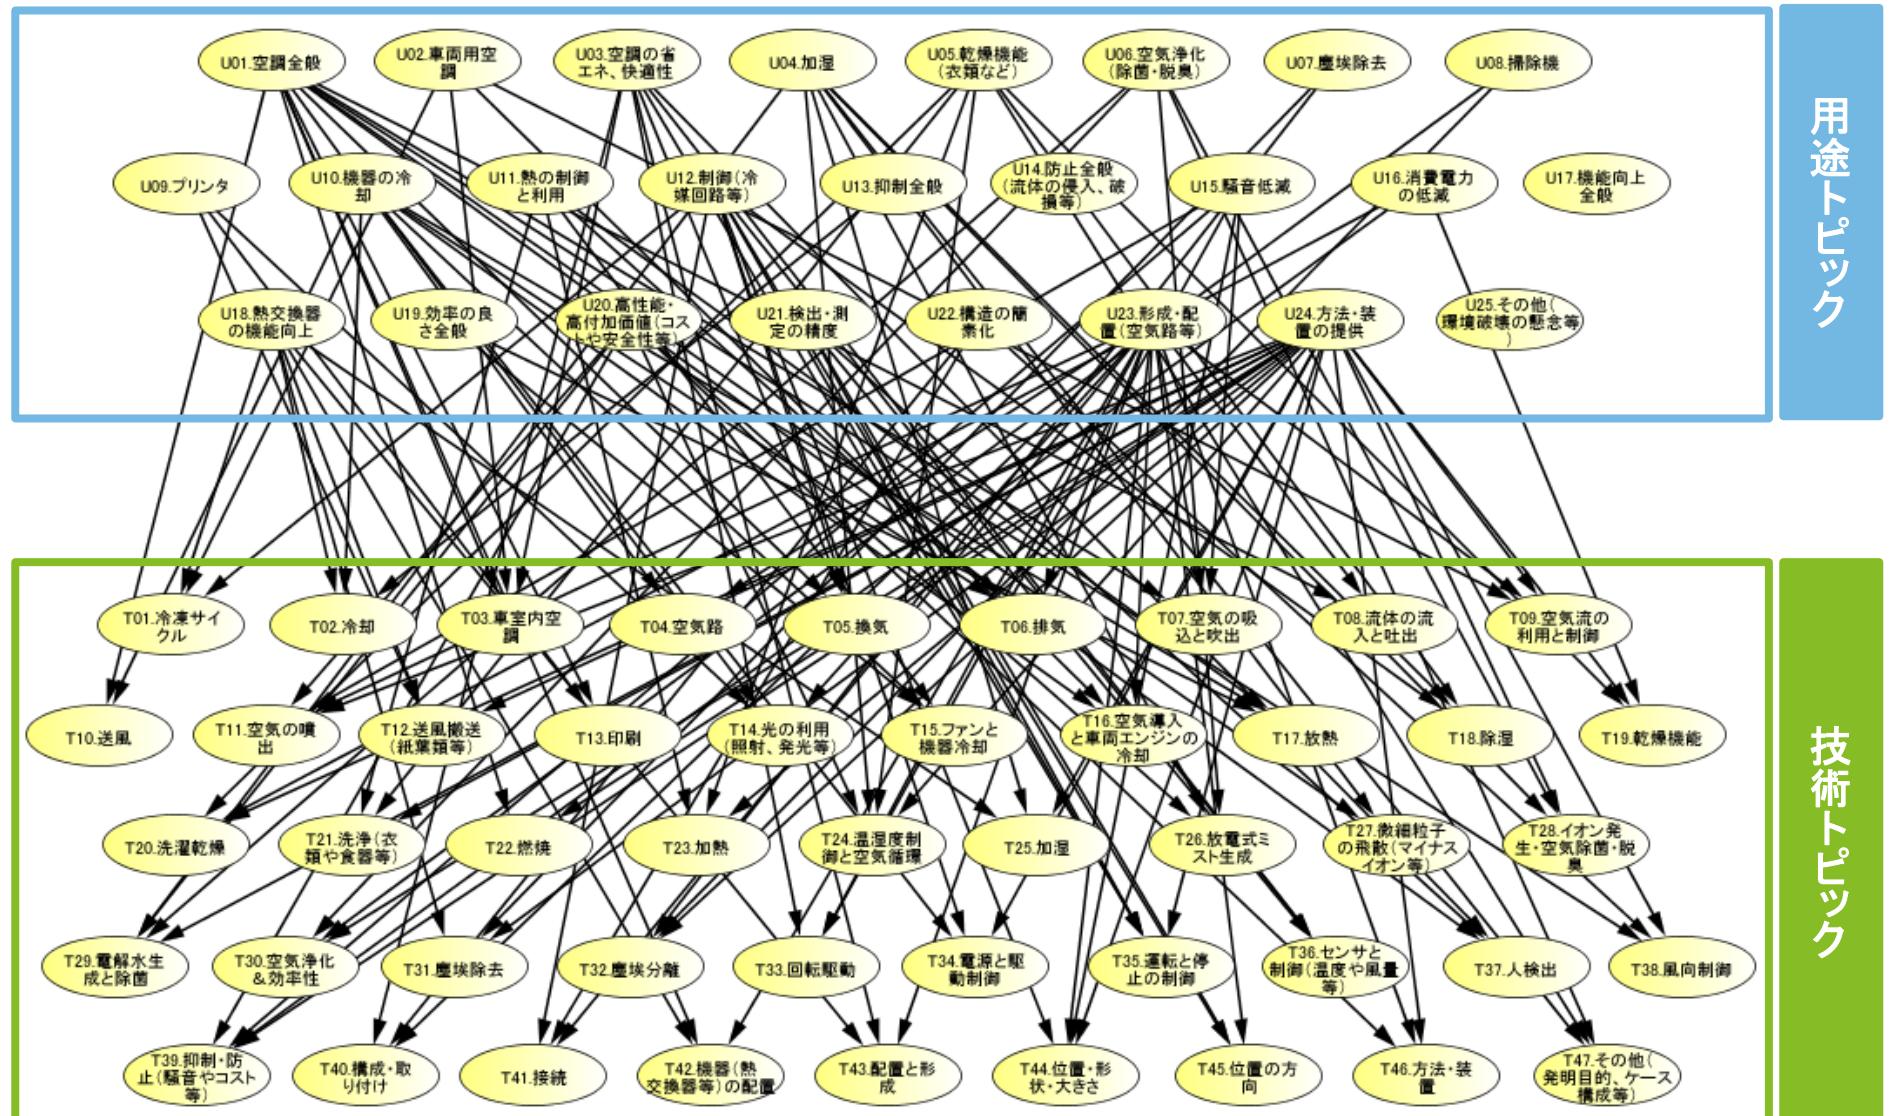
<その1>用途⇒技術の関係

【分析目的】

自社で検討中の用途に対する解決技術を把握し、その用途を達成するためにどの技術開発に注力すべきか、競合となりそうな他社はどこか、他社が牛耳る技術の代替技術は何か、どの出願人と連携すべきかなど、開発戦略や提携戦略を検討する

用途⇒技術の関係モデル

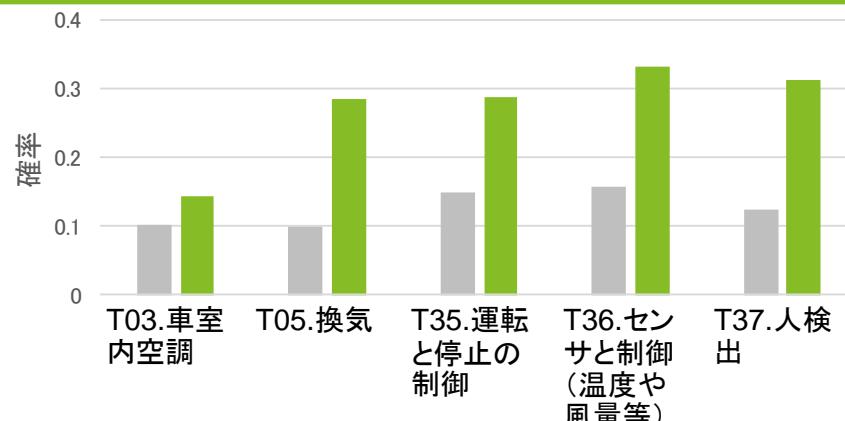
ベイジアンネットワークを適用して、用途トピックに対する技術トピックの確率的因果関係をモデル化します



用途と関係のある技術の確認

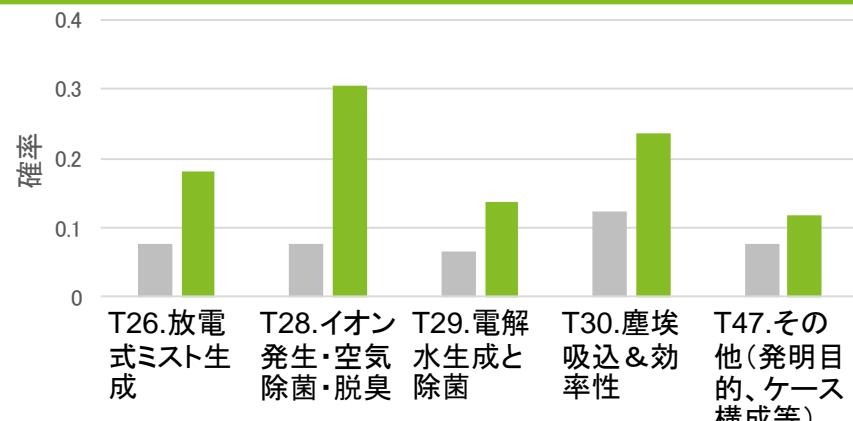
用途トピックを条件に与えたとき、それと確率的因果関係を持つと判定された各技術トピックの確率がどのように変化するのかシミュレーションして、その関連性の強さを確認します

「U03.空調の省エネ、快適性」と関係のある技術



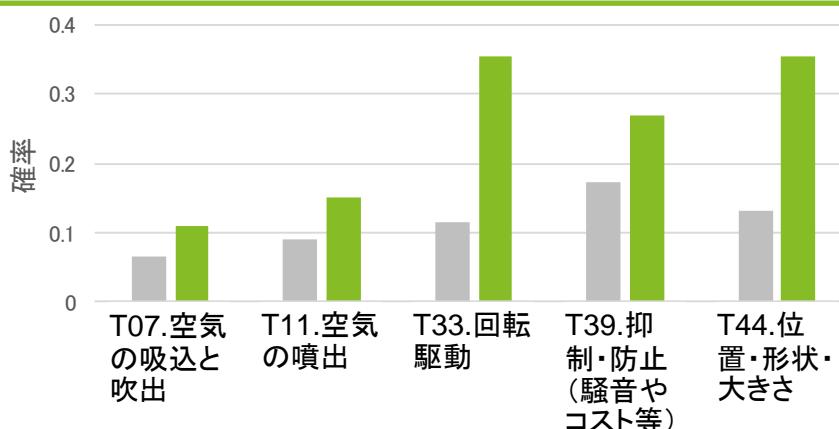
■元々の発生確率(事前確率) ■U03を条件に与えた確率

「U06.空気浄化(除菌・脱臭)」と関係のある技術



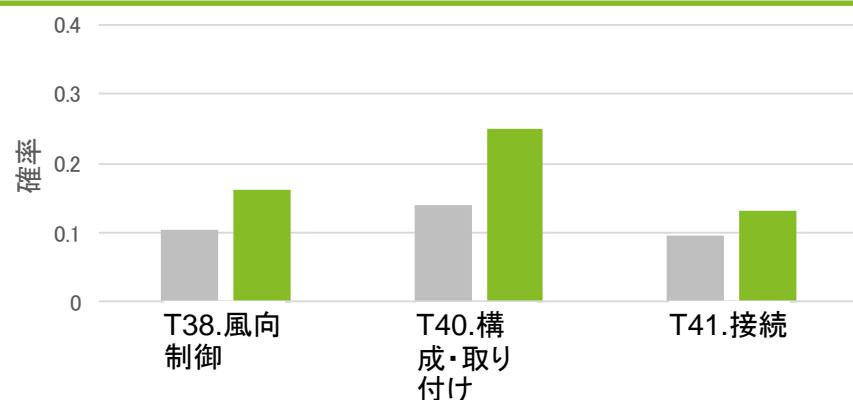
■元々の発生確率(事前確率) ■U06を条件に与えた確率

「U15.騒音低減」と関係のある技術



■元々の発生確率(事前確率) ■U15を条件に与えた確率

「U22.構造の簡素化」と関係のある技術

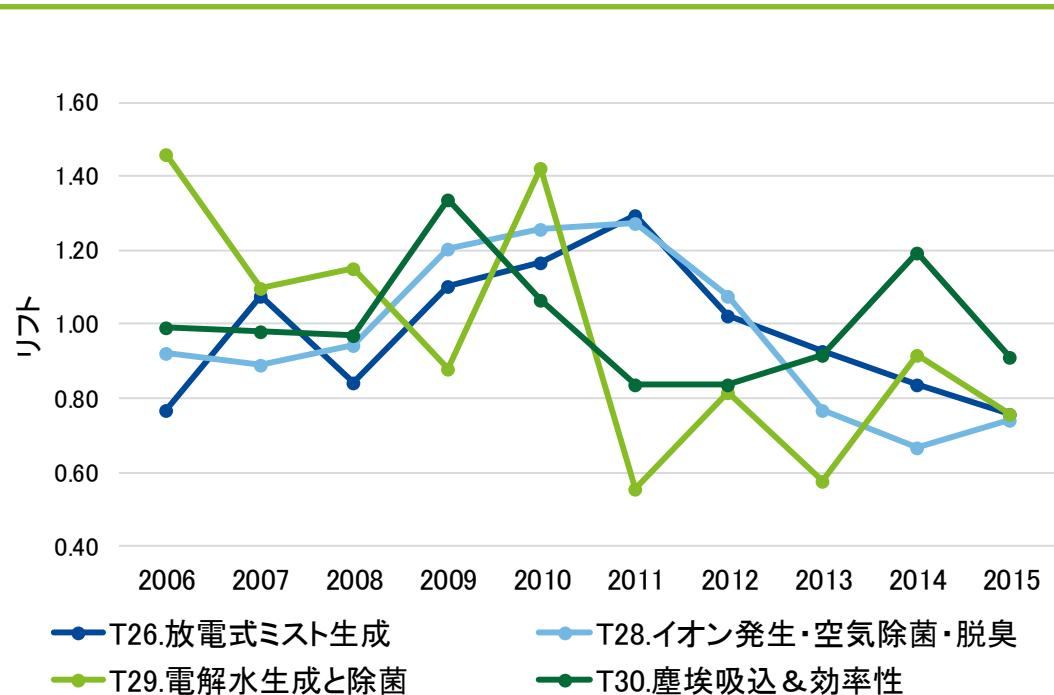


■元々の発生確率(事前確率) ■U22を条件に与えた確率

用途「U06.空気浄化」と関係する技術トピックのトレンド

「U06.空気浄化」の用途に関する技術トピックでは、「T29.電解水生成と除菌」と「T30.塵埃吸込＆効率性」が近年緩やかな上昇傾向にあります

「U06.空気浄化(除菌・脱臭)」の関係技術トピックのトレンド



考察

- 「T26.放電式ミスト生成」と「T28.イオン発生・空気除菌・脱臭」は2009年～2011年をピークに近年は下降傾向にある
- 「T29.電解水生成と除菌」と「T30.塵埃吸込＆効率性」は2011年～2013年をボトムに近年はやや上昇傾向にある

集計の仕方

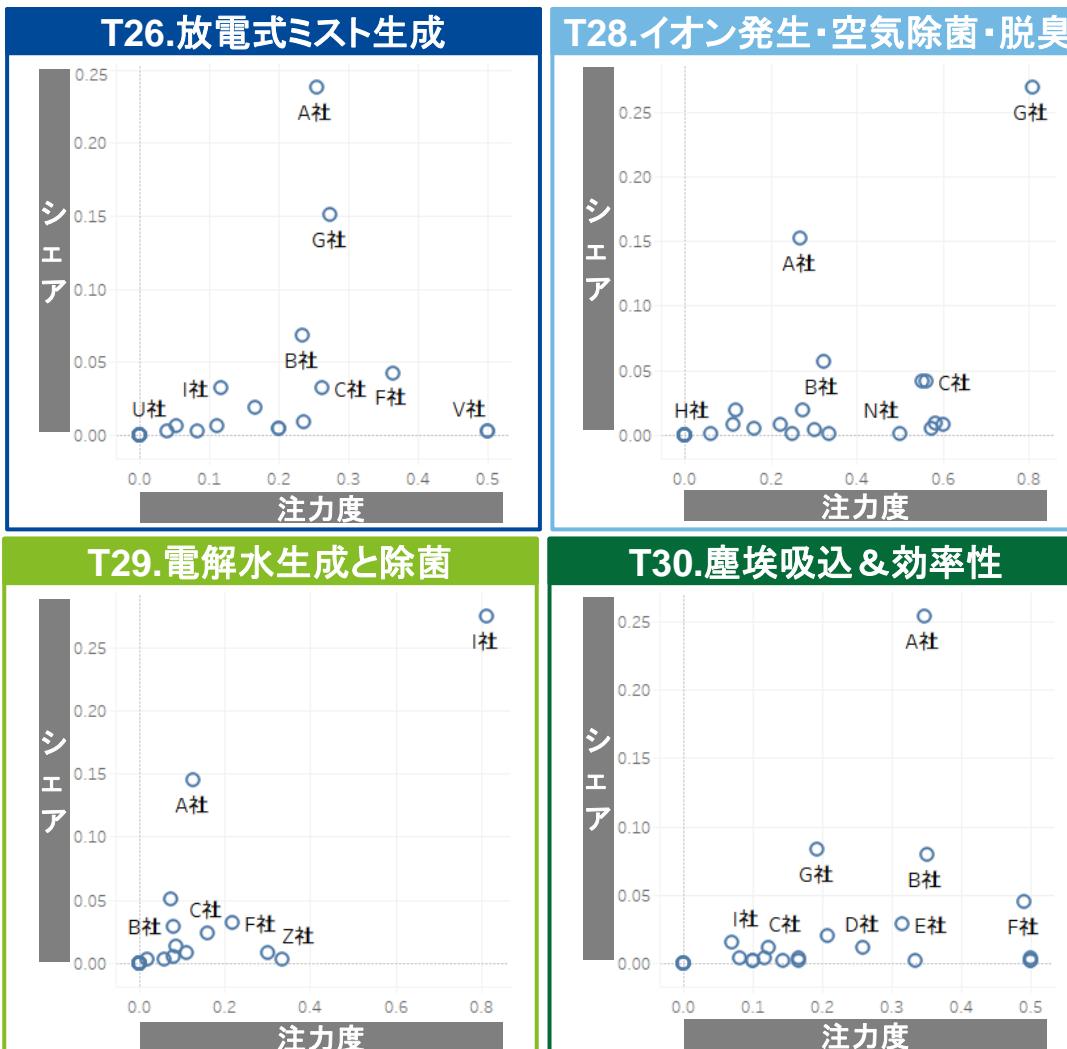
- リフト値を出願年・技術トピックごとに集計
- $$\frac{P(\text{技術トピック } T=1 \mid U06=1, \text{出願年 } Y=1)}{P(\text{技術トピック } T=1 \mid U06=1)}$$

- U06における各技術トピックの該当割合を全体で計算した値(分母)は、各出願年条件下(分子)では何倍になるのかを示す
- U06における各技術トピックの該当割合を全体で計算した値を平均(=1)として標準化したもの

用途「U06.空気浄化」と関係する技術トピックの出願人動向

U06の用途と関係する4つの技術のうち2つは一強状態で、U06にアプローチするためには、この技術を避けた他技術の開発を検討する、あるいはその一強企業との提携も考えられます

「U06.空気浄化」の関係技術トピックにおける出願人マップ



考察と戦略の検討

- 「T28.イオン発生・空気除菌・脱臭」と「T29.電解水生成と除菌」は、それぞれG社とI社が高シェア高注力度のポジションを確立した一強状態の技術といえる
- 「T26.放電式ミスト生成」と「T30.塵埃吸込&効率性」は、高シェア高注力度のポジションは空いているが、どちらもF社がシェアは低いものの注力度が高いポジションにある
- 一強状態の技術を避けて「U06.空気浄化」の用途を実現する場合、T26やT30の技術が狙い目といえるが、注力度の高いF社は要注目である
- 一強状態にあるT28やT29の技術において、その一強企業と提携あるいはM&Aを実現すれば、その技術領域ごと獲得できる

Nomolyticsを適用した特許分析事例

③用途トピック × 技術トピックの関係分析

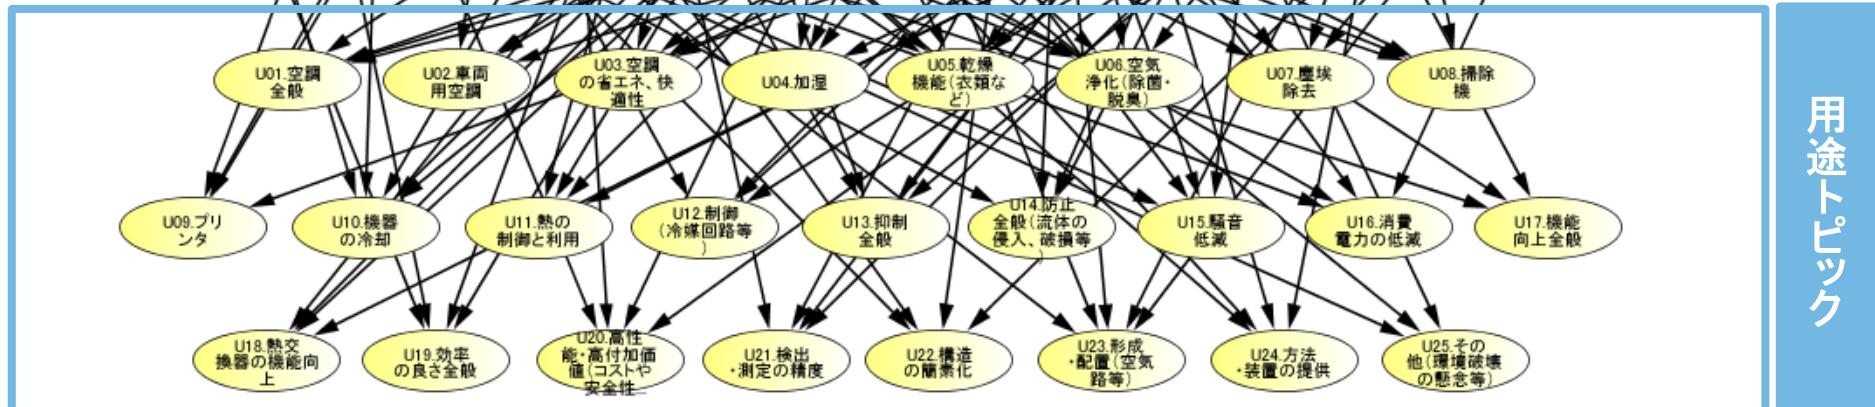
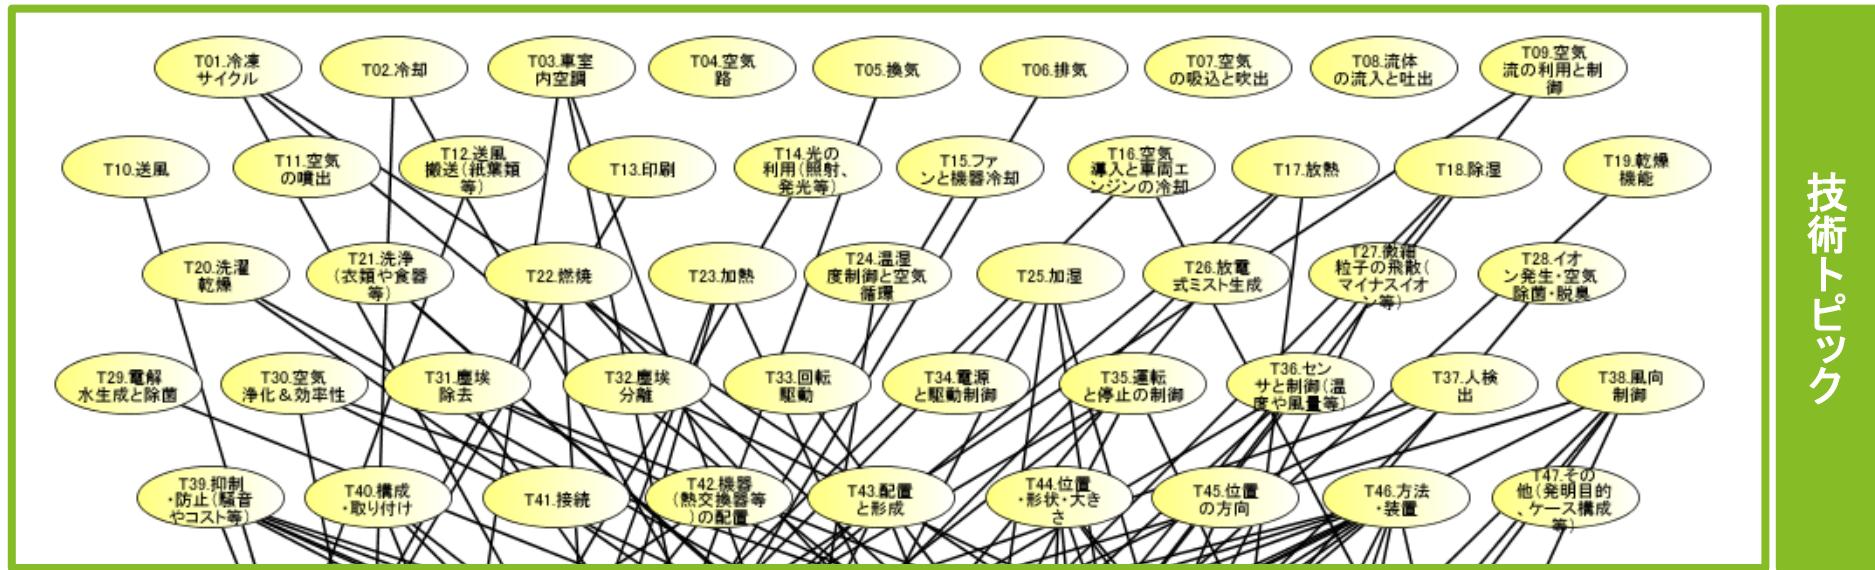
＜その2＞技術⇒用途の関係

【分析目的】

自社技術と関係のある用途を把握し、そのうち自社で想定していない用途を見つけ、その用途に関連する他社の特許文書を探索することで、自社技術を有効活用できる新しい用途展開のアイデアを創出する

技術→用途の関係モデル

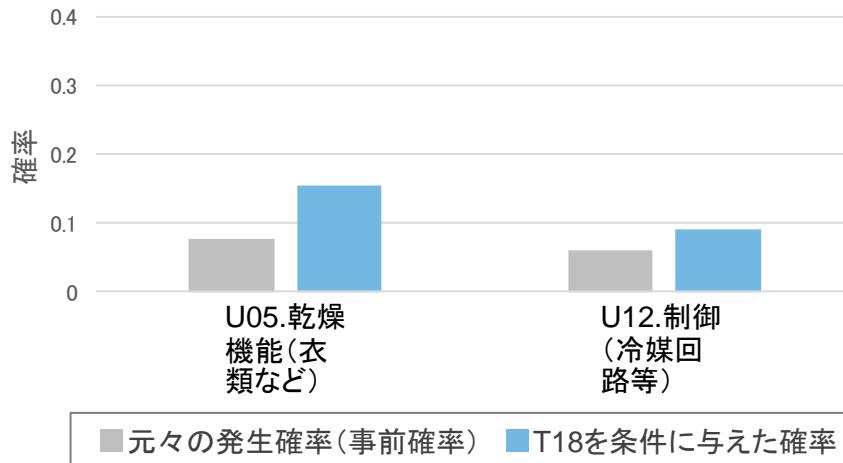
ベイジアンネットワークを適用して、技術トピックに対する用途トピックの確率的因果関係をモデル化します



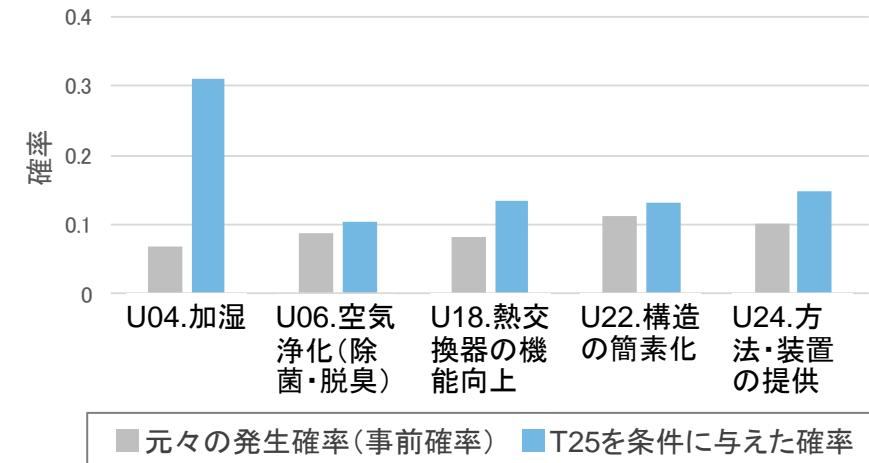
技術と関係のある用途の確認

技術トピックを条件に与えたとき、それと確率的因果関係を持つと判定された各用途トピックの確率がどのように変化するのかシミュレーションして、その関連性の強さを確認します

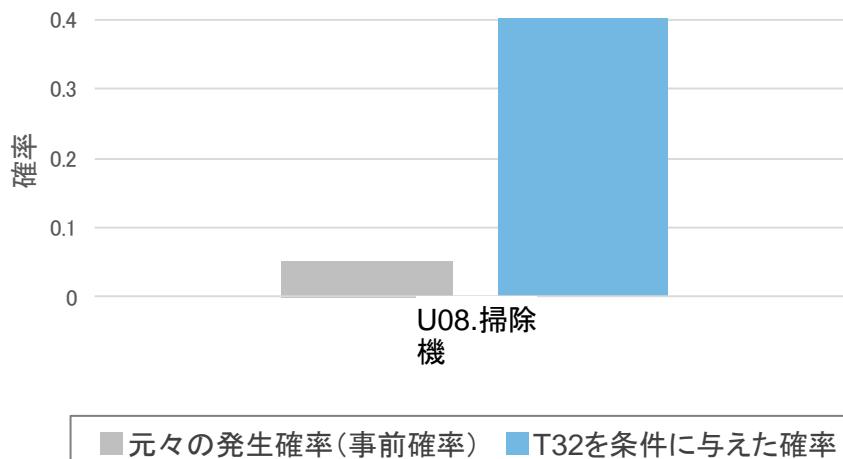
「T18.除湿」と関係のある用途



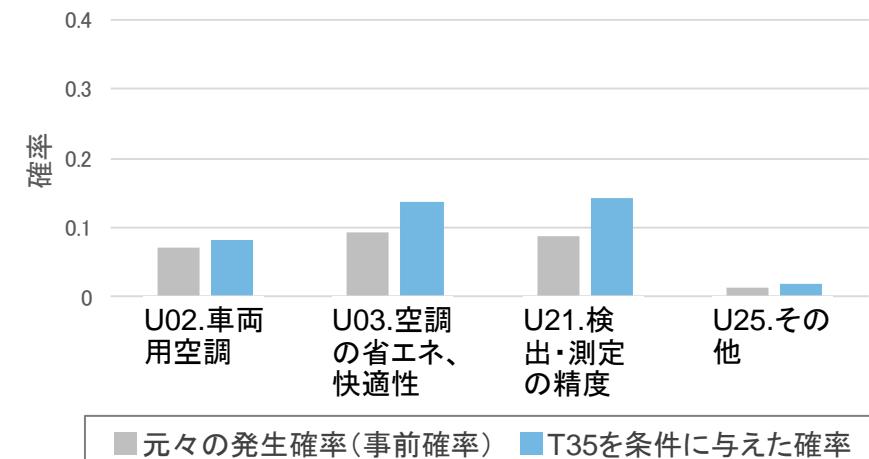
「T25.加湿」と関係のある用途



「T32.塵埃分離」と関係のある用途

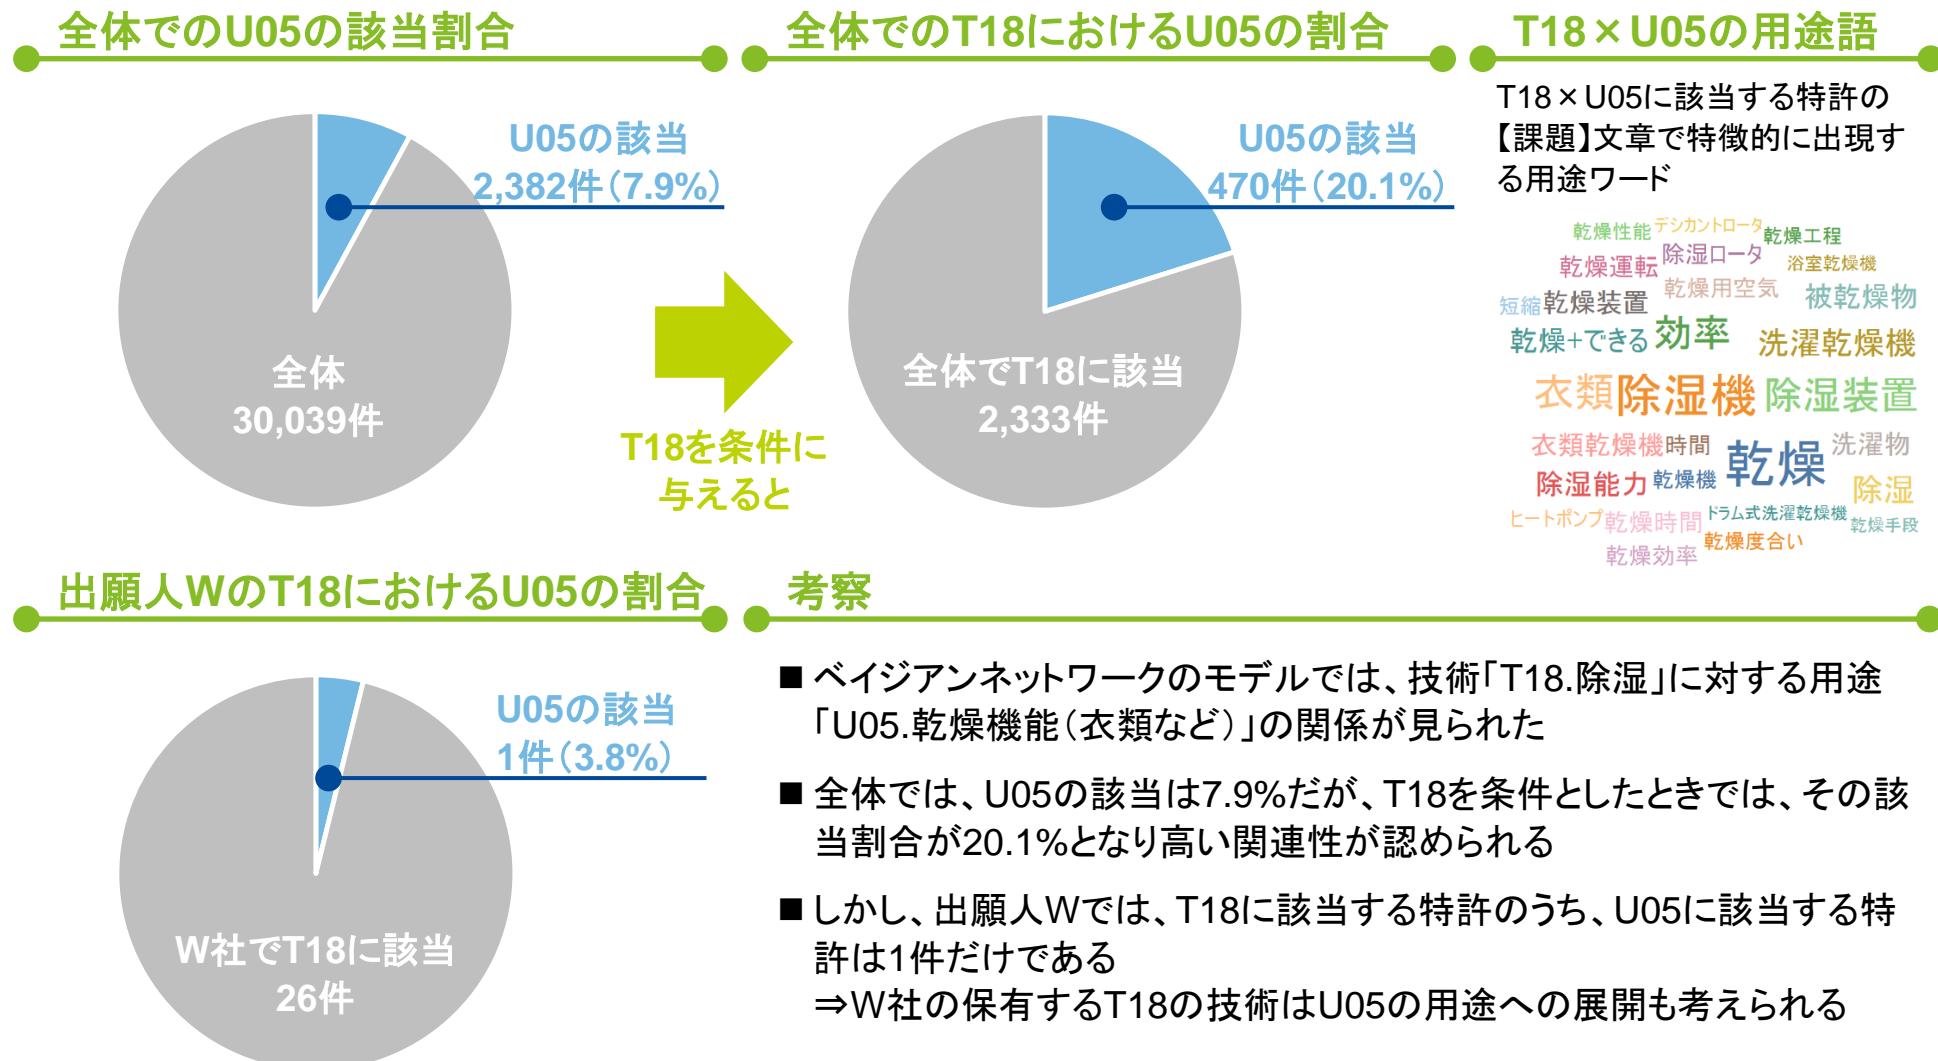


「T35.運転と停止の制御」と関係のある用途



技術「T18.除湿」の用途「U05.乾燥機能」への展開

「T18.除湿」の技術の応用先として「U05.乾燥機能」の用途は高い関連性がありますが、出願人Wの保有するT18ではそれがほとんどなく、新規用途となる可能性があります



「T18.除湿」の技術を「U05.乾燥機能」の用途で応用するアイデア創出

印刷機の中でインク液を吸収した用紙の湿気をムラなく取り除く乾燥処理技術は、洗濯乾燥機の中で洗濯物をムラなく効率的に乾燥させることにも応用できるかもしれません

T18がU05で応用されている例

発明の名称

ドラム式洗濯乾燥機

【課題】

洗濯物を短い時間でムラ無く乾燥させ、乾燥工程の時間を短くすることができるドラム式洗濯乾燥機を提供する。

【解決手段】

送風機に吸い込まれた空気は、風路切替弁の切り替えにより、ドラム開口部に対向する前側吹出口へ流れたり、回転ドラムの後部に設けられた後側吹出口へ流れたりする。制御装置が風路切替弁の切り替えを制御することによって、恒率乾燥過程時、前側吹出口から乾燥用空気が吹き出し、かつ、減率乾燥過程時、後側吹出口から乾燥用空気が吹き出す。これにより、恒率乾燥過程において乾燥用空気が効果的に当たらなかった、回転ドラムの後端壁側の洗濯物に、乾燥用空気が減率乾燥過程で効果的に当たる。

出願人Wの保有するT18の例

発明の名称

インクジェット記録装置及び画像記録方法

【課題】

処理液の厚みムラを低減するとともに処理液による用紙のコックリングを低減することで、高品質かつ高速の画像記録を可能とするインクジェット記録装置及び画像記録方法を提供する。

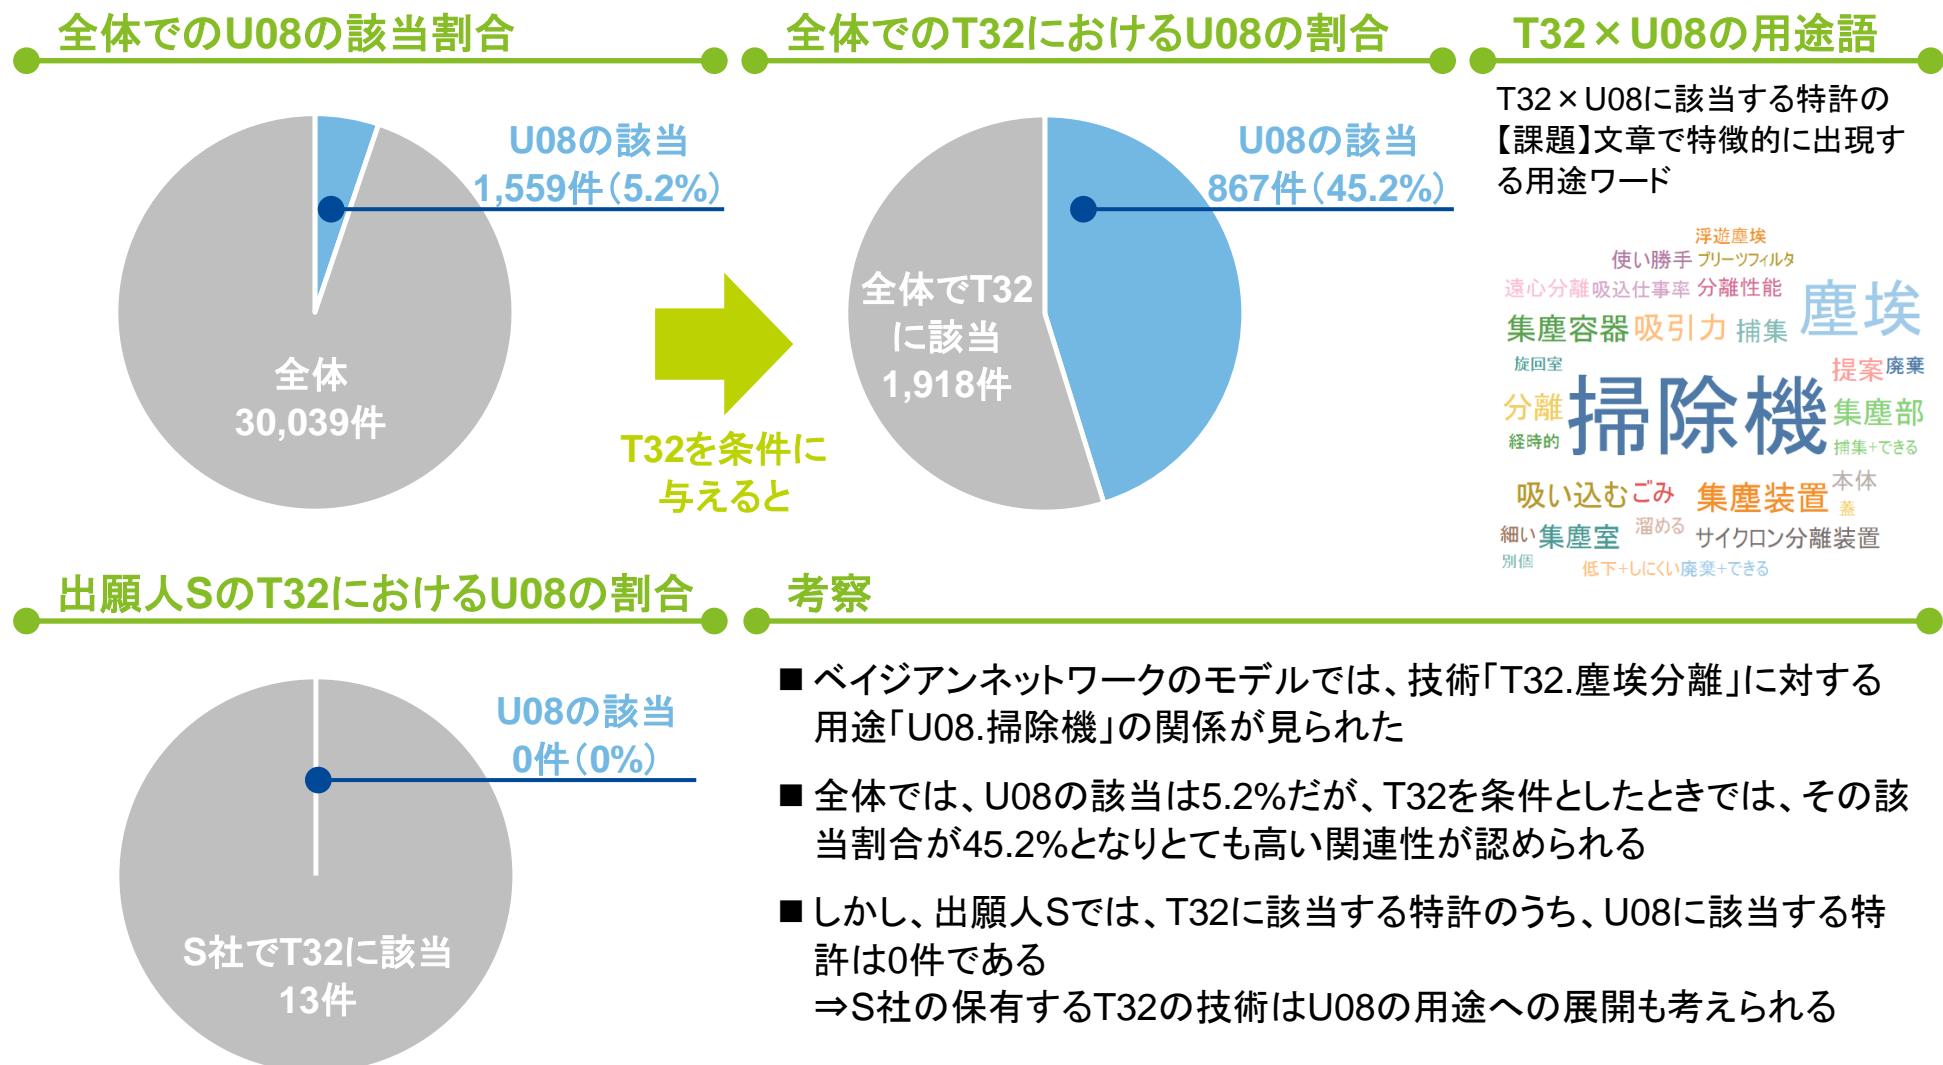
【解決手段】

記録媒体に処理液を付与する処理液付与部の後段には、記録媒体表面に残存する溶媒を蒸発させるプレ加熱部が設けられている。プレ加熱部はIRプレヒータにより記録媒体表面を輻射加熱するとともに、吸引ファンにより記録媒体表面の湿り空気を置換する。液状の処理液が不均一にならないように乾燥処理を施すことで、均一な膜厚を持つ固体状の凝集処理層が形成される。その後、本加熱部による熱風噴射加熱により、コックリング量が所定量以下になるように本加熱処理が施される。

※対外説明用のため要約文は一部加工している

技術「T32.塵埃分離」の用途「U08.掃除機」への展開

「T32.塵埃分離」の技術の応用先として「U08.掃除機」の用途はとても高い関連性がありますが、出願人Sの保有するT32ではそれが全くなく、新規用途となる可能性があります



「T32.塵埃分離」の技術を「U08.掃除機」の用途で応用するアイデア創出

印刷機でトナーを分離・回収するサイクロン部の清掃時期を判断して分離効率を維持する技術は、サイクロン掃除機の集塵部の集塵性能を向上させることにも応用できるかもしれません

T32がU08で応用されている例

発明の名称

電気掃除機

【課題】

集塵性能が向上しメンテナンスの軽減が図れる電気掃除機を提供すること。

【解決手段】

塵埃を含む空気を旋回させ塵埃分離する略円筒状の1次旋回室と、1次旋回室に連通した2次旋回室と、1次旋回室の下方に位置し塵埃を溜める集塵室と、塵埃を圧縮する圧縮板と、塵埃が流入する流入口を有し、圧縮板の底面の一部に突出部を流入口から見て集塵室の奥側に配設する構成としたことより、集塵室内に入った塵埃は、圧縮板の突出部に引っかかり動きが止められ、流れに乗って2次旋回室や1次旋回室側に戻ることが無いため集塵性能が向上し、排気筒の詰まり防止によるメンテナンスの軽減を図ることができる。

出願人Sの保有するT32の例

発明の名称

画像形成装置

【課題】

サイクロン部の清掃時期を適正に判断して、トナーの分離効率の低下を抑制することが可能な画像形成装置を提供する。

【解決手段】

画像形成装置は、トナー含有空気からトナーを遠心分離するサイクロン部と、サイクロン部によって分離されたトナーを回収する回収部と、サイクロン部によってトナーが分離された空気を通過させ、残留トナーを捕集するフィルタ部と、空気を吸引する送風部と、フィルタの汚れを検知する汚れ検知センサが設けられたトナー捕集部を備え、汚れ検知センサで検知されたフィルタの汚れから推定した風量と、風速センサで取得した風量の実測値の差分が、サイクロン清掃閾値を超えたと判断すると、サイクロン部の清掃モードを実行する。

※対外説明用のため要約文は一部加工している

まとめ

膨大なテキストデータをトピックに変換して解釈を容易にし、テキスト情報内に潜む要因関係をモデル化して、ビジネスアクションに有用な特徴を把握可能にします

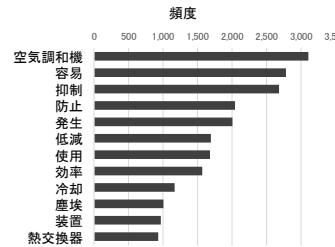
Nomolytics: Narrative Orchestration Modeling Analytics

テキストマイニング

文章に含まれる単語を抽出し、その出現頻度を集計する

単語抽出

Text Mining Studio



PLSA 確率的潜在意味解析

単語が出現する文脈を学習し、膨大な単語を複数のトピックにまとめる

トピック抽出

Visual Mining Studio

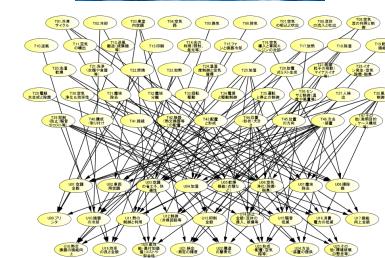


ベイジアンネットワーク

トピックやその他属性情報など、テキスト情報内の要因関係をモデル化する

モデリング

BayoLink



膨大なテキストデータ
を人間が理解しやす
い形に整理できる

テキスト情報内に潜
む複雑な要因関係を
構造化できる

条件を変化させたと
きの結果の挙動をシ
ミュレーションできる

ある事象の発生確率
をコントロールする条
件を発見できる

テキストマイニングに加え、トピックを抽出するPLSAと、そのトピックの関係をモデル化するベイジアンネットワークを適用することで、特許情報に潜む特徴を分かりやすく把握できました

A. 用途と技術のトピック抽出

データの抽出



テキストマイニング

用途トピックの抽出

テキストマイニングを行って単語と係り受け表現を抽出する

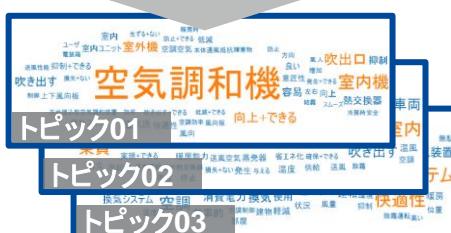
単語	品詞	頻度
空気調和機	名詞	3,106
空気	名詞	2,846
容易	名詞	2,790
抑制	名詞	2,687
...

- 特許文書の要約文の「課題」と「解決手段」のテキストデータを抽出する
- 「課題」からは用途トピックを、「解決手段」からは技術トピックを抽出する

PLSA

「単語 × 係り受け」の共起行列を作成し、これにPLSAを適用してトピックを抽出する

単語	係り受け			
	機 空 提 供	空 氣 調 和	効 率 良 い	提 供 掃 除 機
空気調和機	1,578	100	1	
空気	85	144	45	
容易	190	105	67	



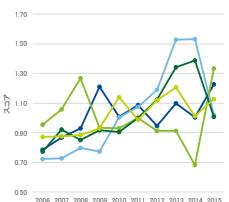
B. トピックの特徴集計

全特許データに各トピックのスコア(該当度)を計算する

ID	出願年	出願人	用途トピック1	用途トピック2	用途トピック*	技術トピック1	技術トピック2	技術トピック*
1	2014	A社	2.1	0.6	...	1.5	5.0	...
2	2013	B社	0.3	3.4	...	4.6	0.9	...
3	2011	C社	4.8	2.2	...	2.7	1.1	...
n

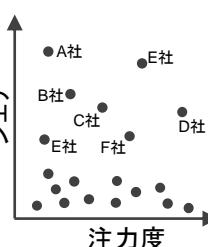
出願年集計

トピックスコアを出願年で集計してトピックのトレンドを把握する



出願人集計

トピックスコアを出願人で集計して、各トピックにおける出願人の特徴を把握する



用途トピックと技術トピックの統計的な関係性をベイジアンネットワークでモデル化する

ベイジアンネットワーク

技術トピック



用途トピック



用途⇒技術

自社で検討中の用途に対してその解決技術の候補を把握し、他社で想定しているが注力していない技術あるいは保有済みの技術を探索することで、自社技術の新規用途を探査し、開発戦略や提携戦略を創出する検討する

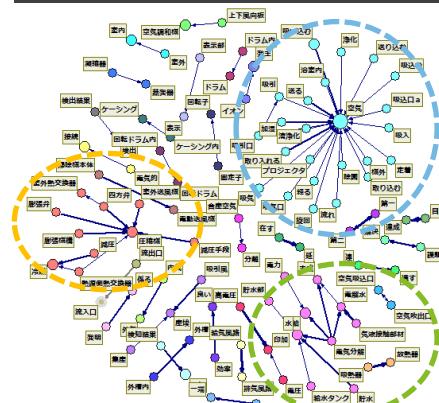
技術⇒用途

Nomolyticsを適用した特許分析のメリット①

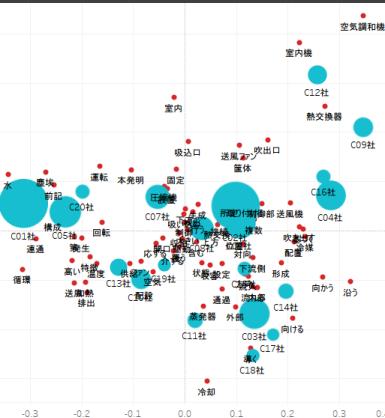
単語ではなく集約されたトピックをベースにした分析を実行することで、膨大な特許情報に潜む特徴を分かりやすく理解することができます

従来の特許分析

単語の共起ネットワーク



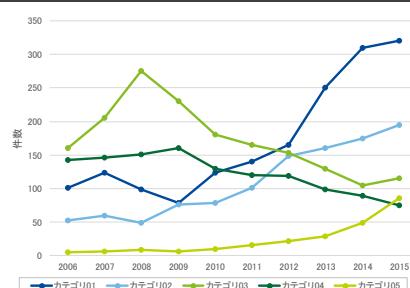
単語と出願人の対応マップ[®]



カテゴリのリスト作成

掃除機カテゴリのリスト	
掃除機	塵埃->分離
集塵	塵埃->吸い込む
集塵容器	塵埃->収容
吸引力	塵埃->遠心分離
サイクロン	含塵空気->分離

カテゴリ別のトレンド



■ 単語ベースのアウトプットから、文章全体に存在する話題を解釈したり、各出願人の特徴を把握しなければならない

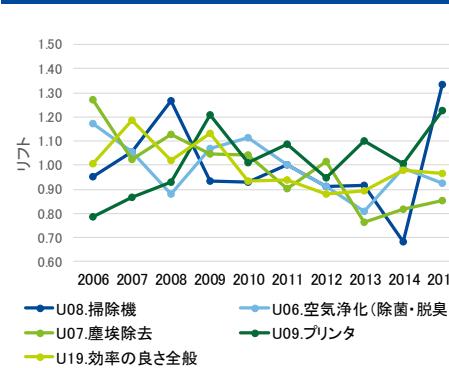
■ 単語を人手でグルーピングしていくつかのカテゴリを作成して、カテゴリベースに分析するものの、そのカテゴリ作成は属人的で作業負荷も大きい

Nomolyticsを適用した特許分析

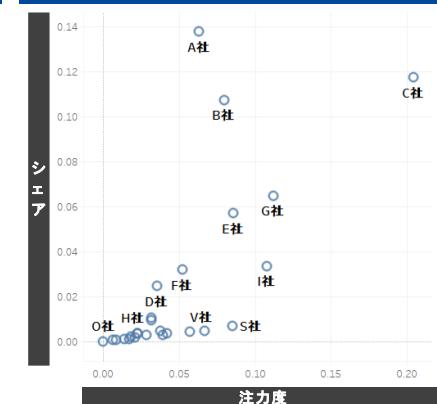
PLSAによって機械的に抽出されたトピック



トピック別のトレンド



トピック別の出願人の配置



■ 文章全体に存在する話題をPLSAで機械的に抽出できる

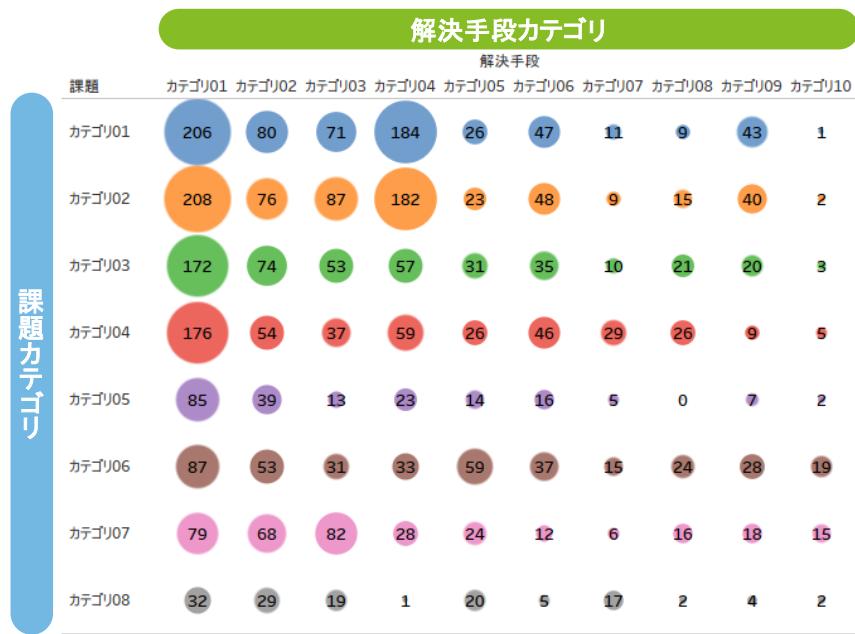
■ 単語ではなくトピックをベースにトレンドや各出願人の特徴を分析し、分かりやすく理解することができる

Nomolyticsを適用した特許分析のメリット②

用途と技術の統計的な関係を把握することで、各用途を実現するための重要技術を確認して技術戦略を検討したり、自社技術を有効活用できる新規用途のアイデアを創出できます

従来の特許分析

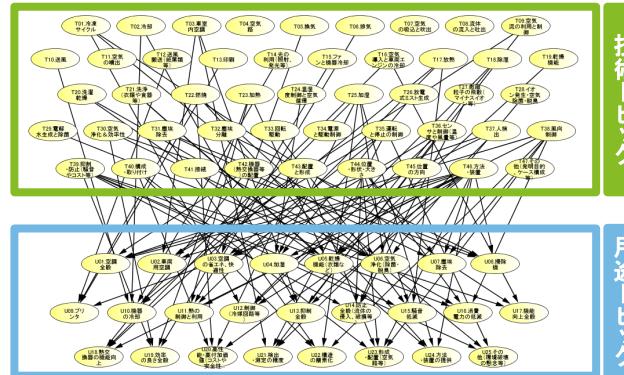
課題と解決手段のカテゴリ間のクロス集計



- 【課題】と【解決手段】それぞれに対して人がグルーピングして作成したカテゴリのクロス集計表を作成し、その対応関係を考察する
- その組み合わせで出願件数が多いからといって、統計的に意味のある関係であるとは限らない(全体的に出願件数が多い可能性もある)

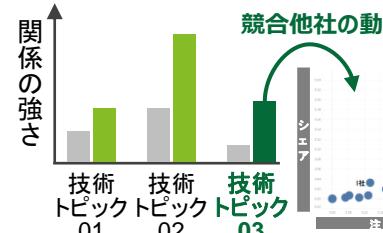
Nomolyticsを適用した特許分析

課題と解決手段のトピック間の統計的な因果関係モデル

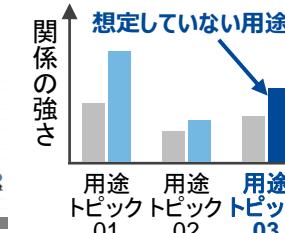


分析目的に応じて因果構造を入れ替える
①「技術 ⇒ 用途」
②「用途 ⇒ 技術」

想定用途と関係のある技術



自社技術と関係のある用途



関連する他の特許文書は？
ドラム式洗濯乾燥機
【課題】洗濯物を短い時間でムラ無く乾燥させ、乾燥工程の時間を短くすることができるドラム式洗濯乾燥機を提供する。
【解決手段】送風機に吸い込まれた空気は、風路切替弁の切り替わりにより、ドラム

- 客観的に抽出されたトピックをベースに課題と解決手段(用途と技術)の統計的な関係をベイジアンネットワークで把握できる
- 検討中の用途に対して、関係の強い技術を確認し、各技術のトレンドや出願人の動向から自社の技術戦略を検討できる
- 自社技術と関係の強い用途で想定していないものを確認し、その関連特許の探索から技術の新規用途アイデアを創出できる

Nomolyticsは様々な業務のテキストデータに適用することができます



口コミ

- 顧客の関心トピックのターゲット別把握
- 顧客目線での製品や競合の比較分析
- 満足度向上の要因の把握
- 値値観を理解したマーケティング検討



アンケート

- 自由記述の内容をトピック化
- 自由記述トピックを変数として扱うことで定型設問回答と一緒に分析可能
- 話題を生む要因の把握



コールセンター履歴

- 問い合わせ内容をトピック化
- 製品別・顧客別の問い合わせ特徴把握
- 問い合わせトピック等の条件から解約確率をシミュレーション



特許文書

- 課題と技術のトピックのトレンド把握
- 競合他社の技術動向把握
- 課題と技術のトピックの関係モデル化による保有技術の新規用途探索



営業日報

- 営業活動内容のトピック化
- 営業活動トピック等の条件から成約確率をシミュレーション
- 成約要因を把握した効果的な営業教育



有価証券報告書

- 各企業の事業内容をトピック化
- 事業トピックとそのトレンド把握
- 各種IR指標と事業トピックの関係分析
- 定性情報からの企業分析、業界分析



エントリーシート

- 志望動機やPR文のトピック抽出
- 記述内容からの学生の分類・振り分け
- 記述内容と入社後成果の関係分析
- 効率的な人材発掘



診療記録

- 診療記録、看護記録のトピック化
- 生活習慣と病状の関係分析
- 治療内容とその経過の関係分析
- 定性情報を用いた効果的な診療支援



問題発生レポート

- 不具合やヒヤリハット等のトピック抽出
- 作業環境等の条件から問題の発生確率をシミュレーション
- 効果的な製品や作業環境の改善支援

資料に関するお問い合わせやコンサルティングの
ご相談は以下までお願いします。

analytics.office@analyticsdlab.co.jp

会社ホームページもご参考にしてください。
過去の講演・論文資料や技術解説も掲載しています。

<http://www.analyticsdlab.co.jp/>

株式会社アナリティクスデザインラボ

