



BigGorilla

BigGorillaの活動紹介

～データ前処理ノウハウの共有化に向けて～

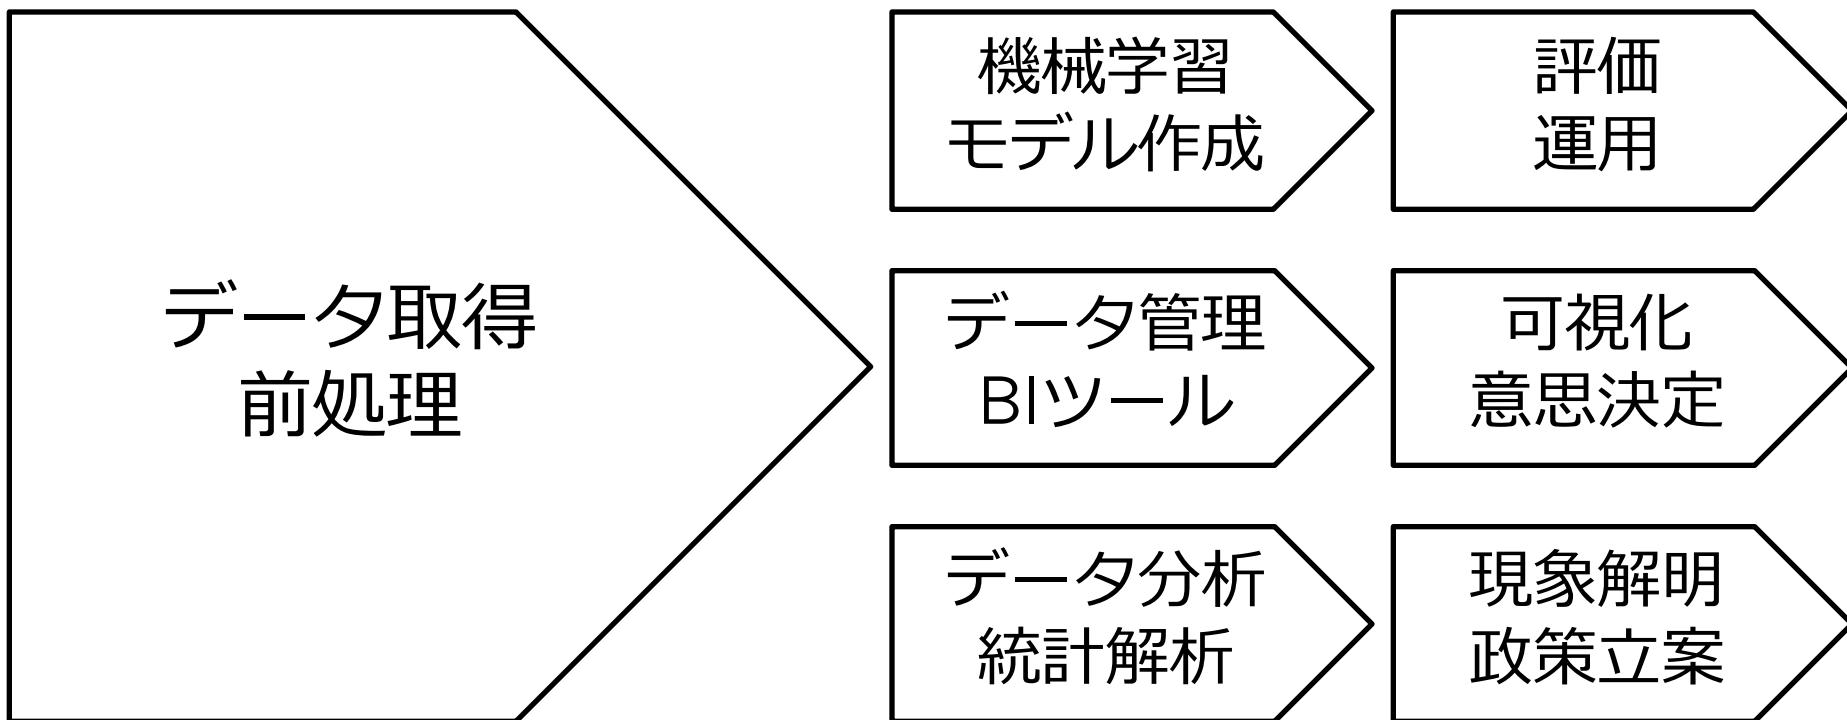


RECRUIT Institute of Technology 山下 宙元



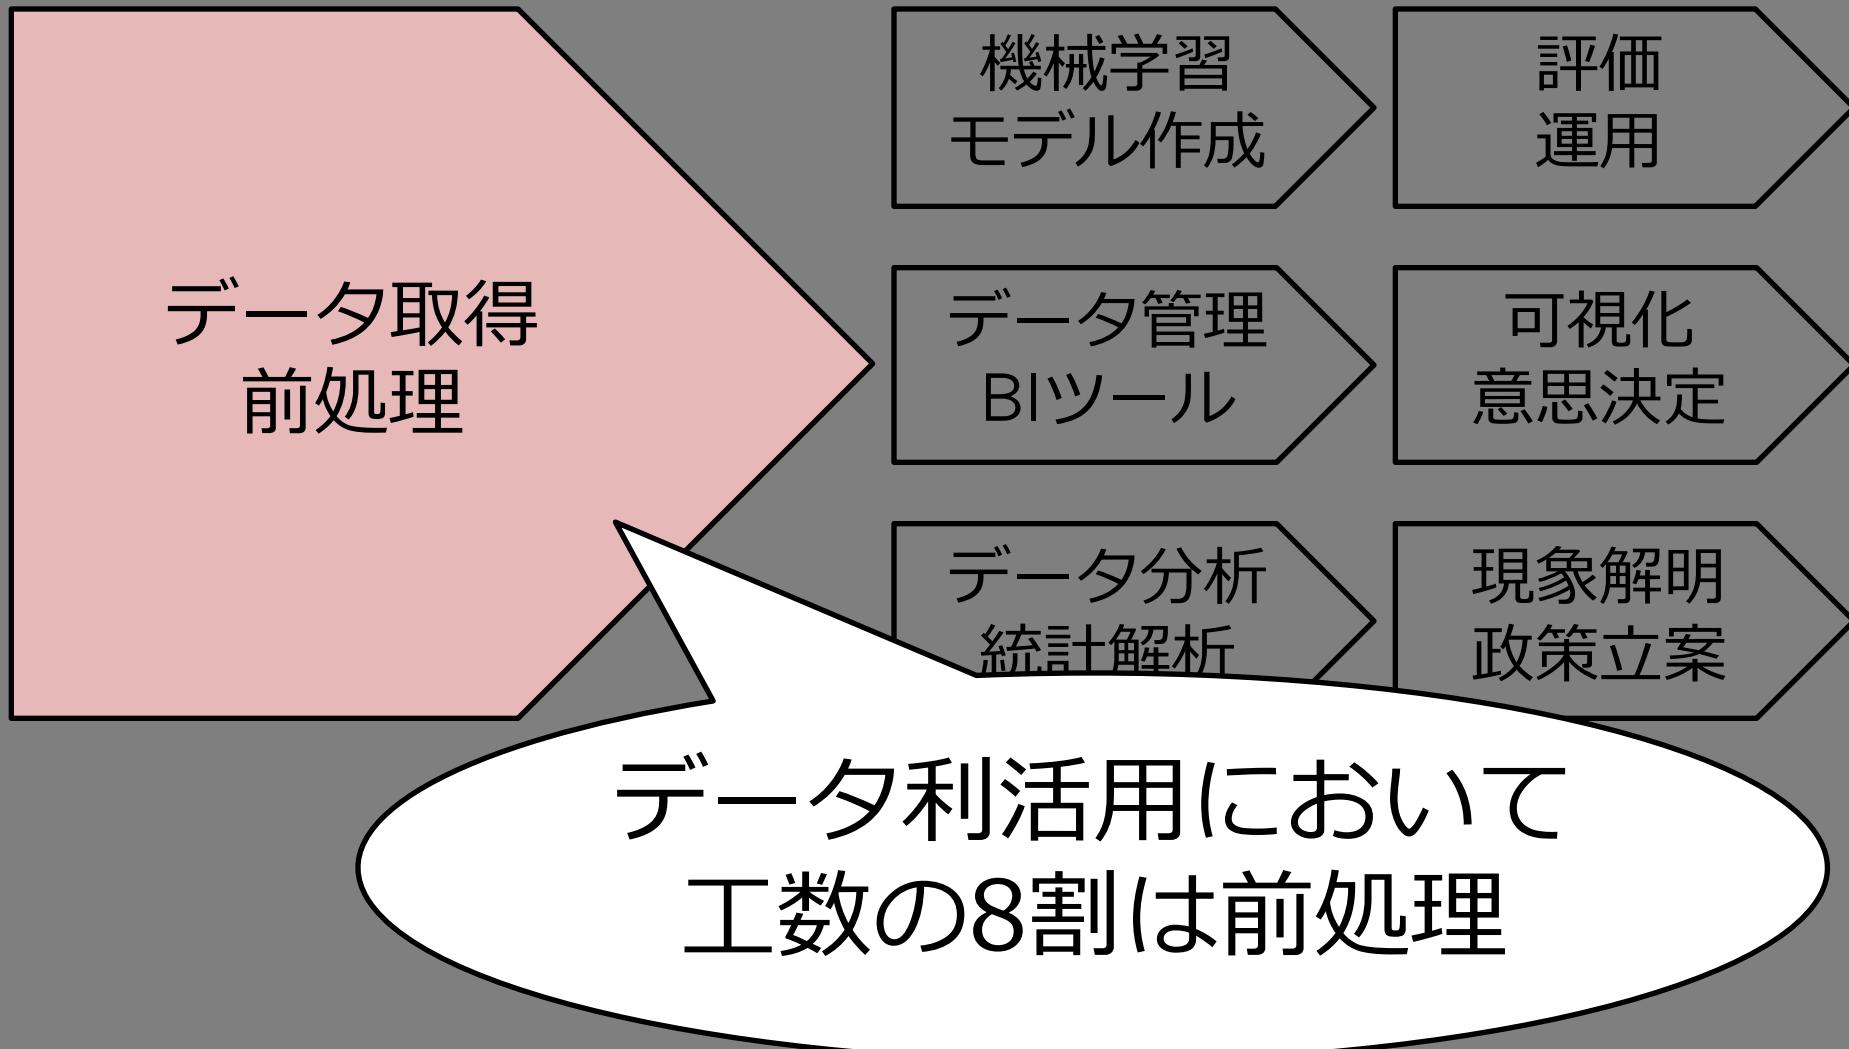
BigGorilla

データ活用のフロー

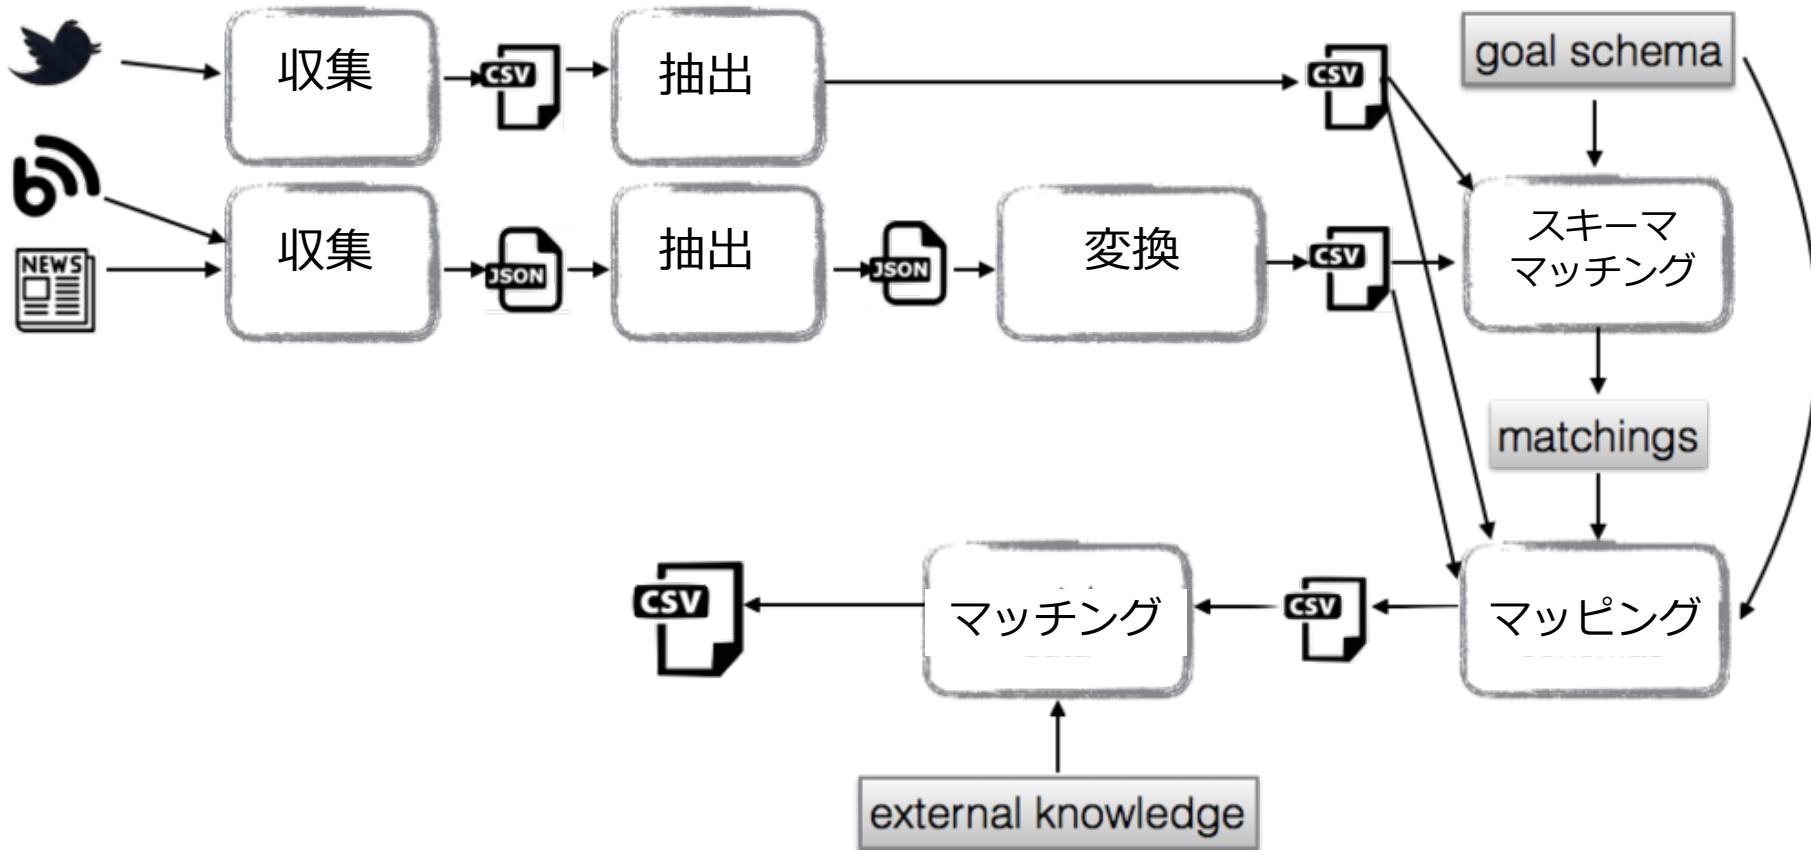


データ量の急速な増加、オープン分析ツールの増加により
データの利活用が高まっているが…

データ活用のフロー

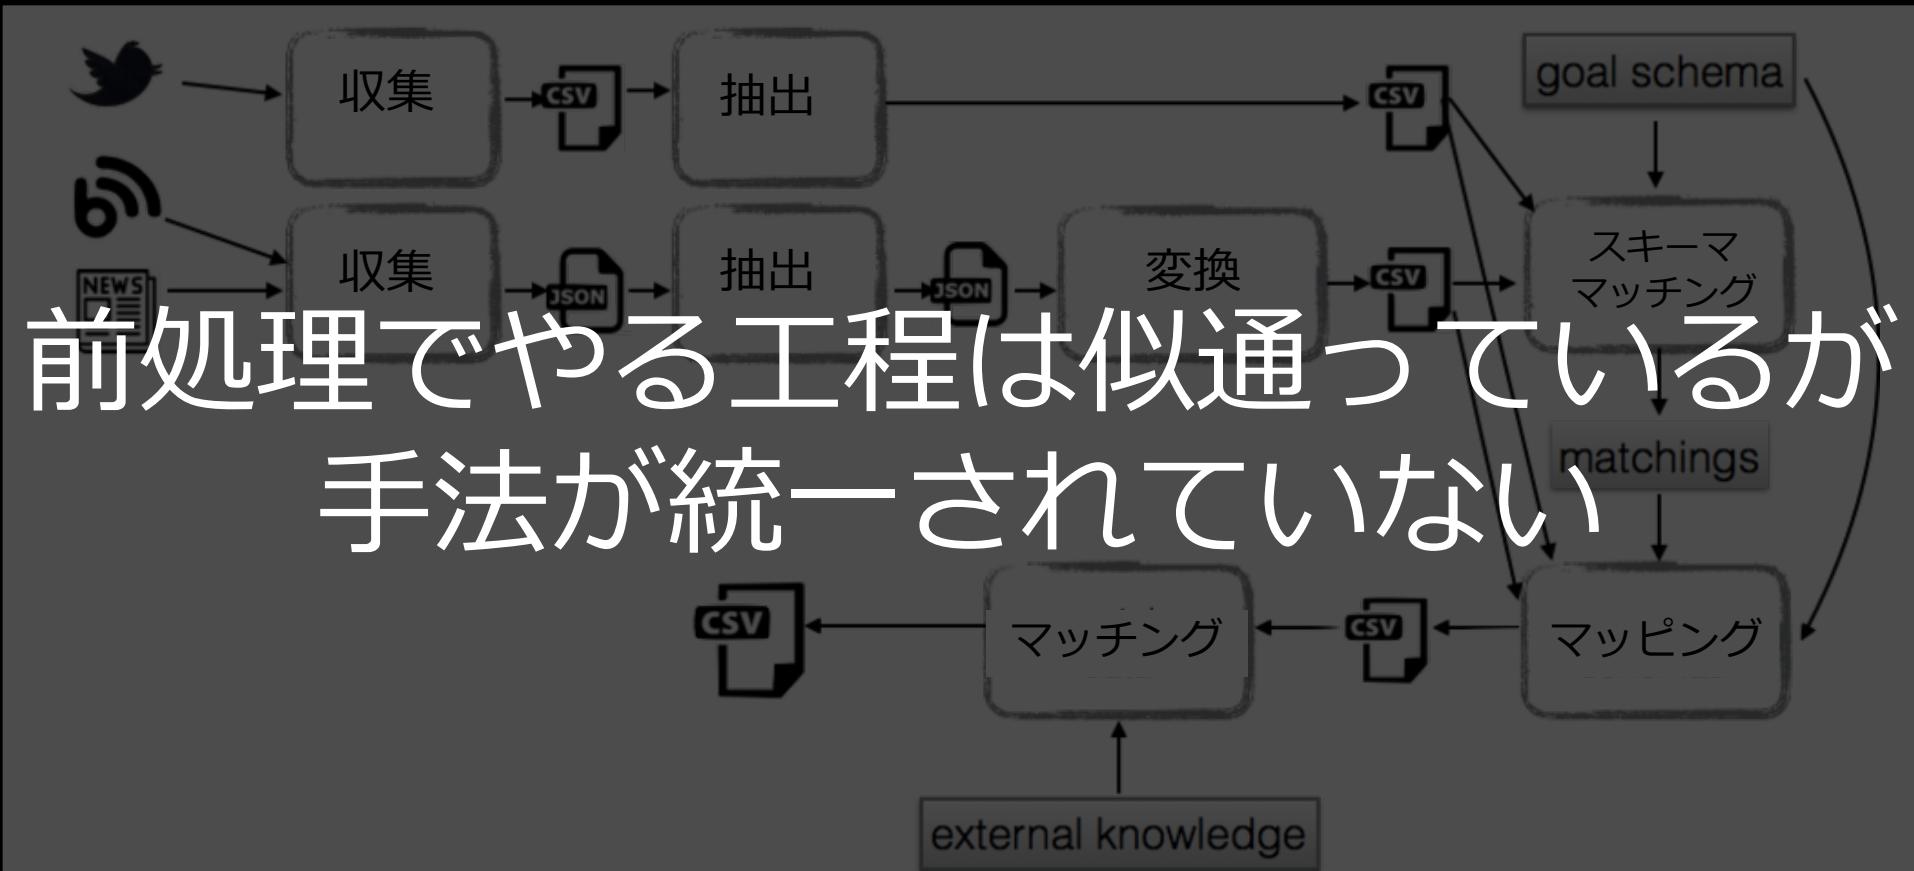


前処理には複数のタスクがある



前処理には複数のタスクがある

前処理でやる工程は似通っているが
手法が統一されていない



BigGorillaのミッション

■ BigGorilla とは？

データ準備とデータ統合のためのオープンソース・エコシステムを開発/啓蒙する**オープンコミュニティ**
(RITとWisconsin大学によりプロジェクト開始)

■ 活動の目的

データに向き合う人が直面する困難を解決するための
知識共有の場（ソフトウェア/ワークフロー/データセット）
となること

ケーススタディ ～表記揺れのあるデータセットの名寄せ～

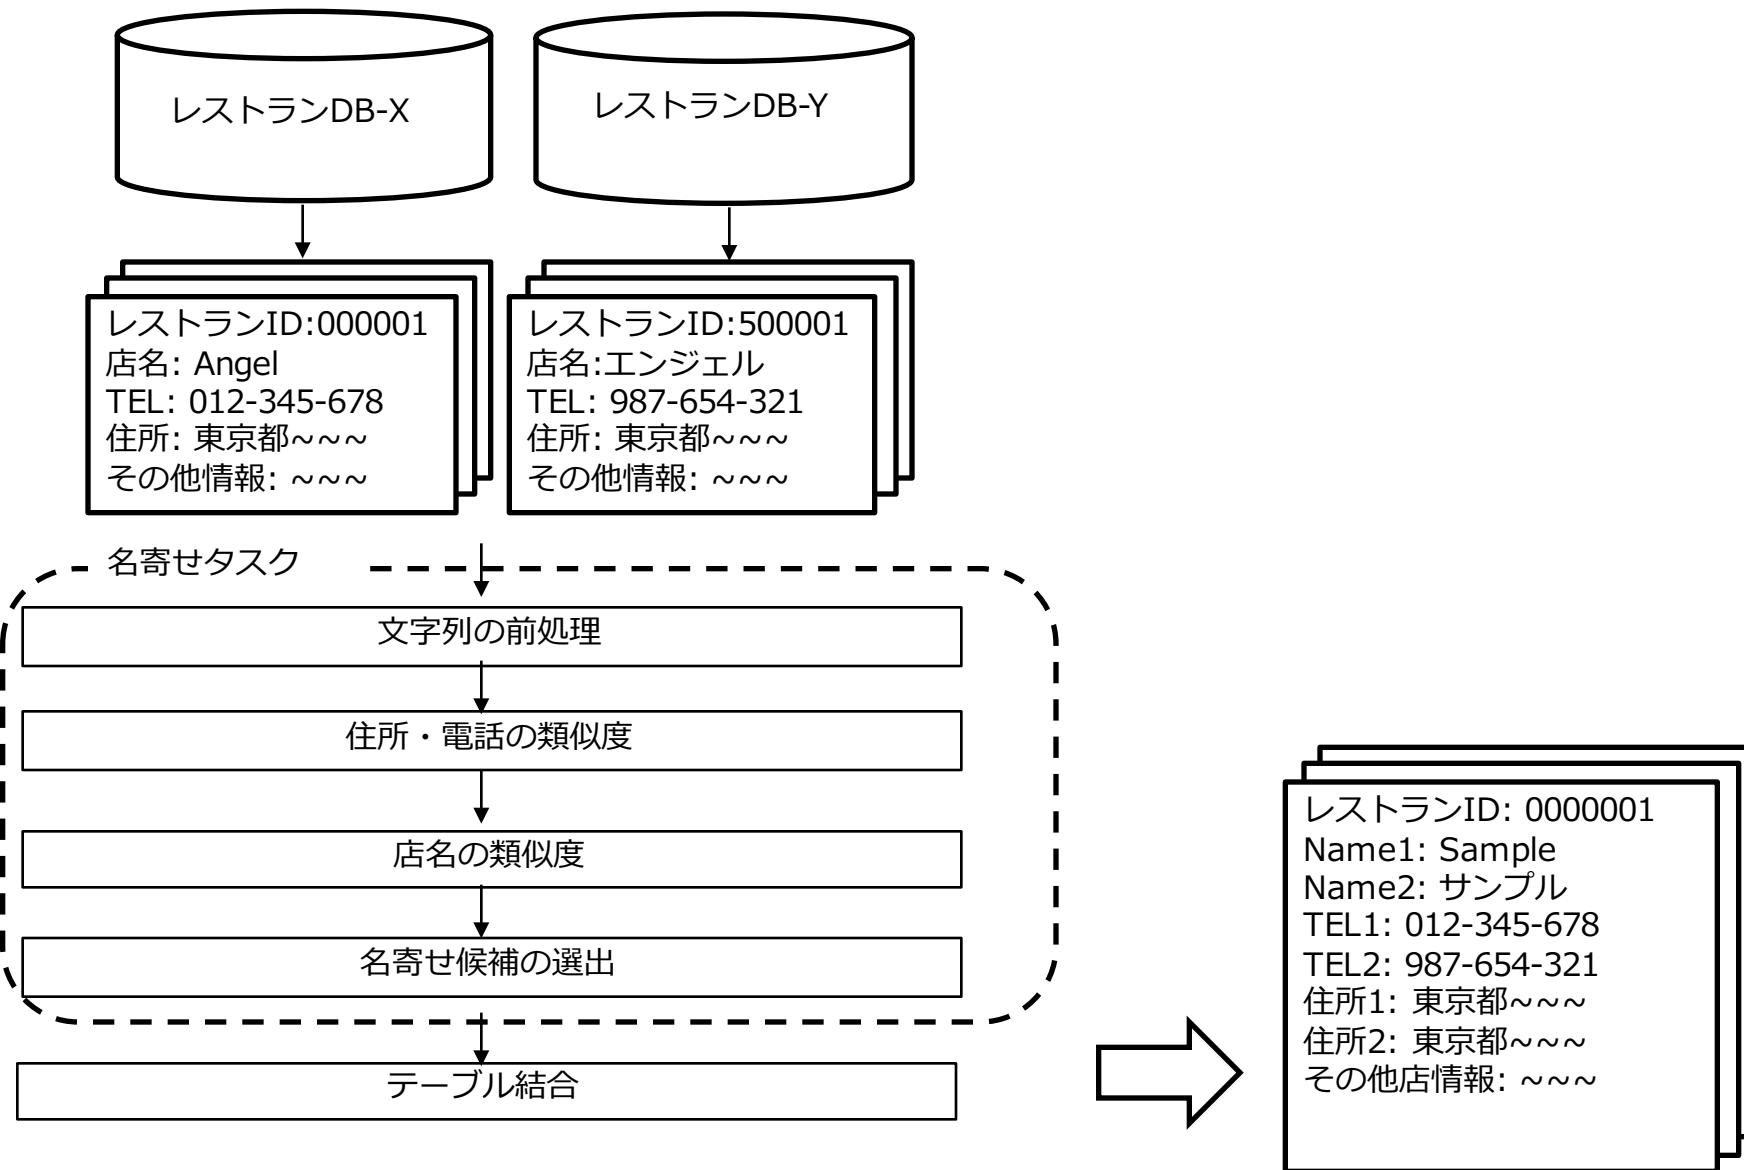
レストランID:000001
店名: Angel
TEL: 012-345-678
住所: 東京都~~~
その他情報: ~~~

レストランID:500001
店名: エンジェル
TEL: 987-654-321
住所: 東京都~~~
その他情報: ~~~

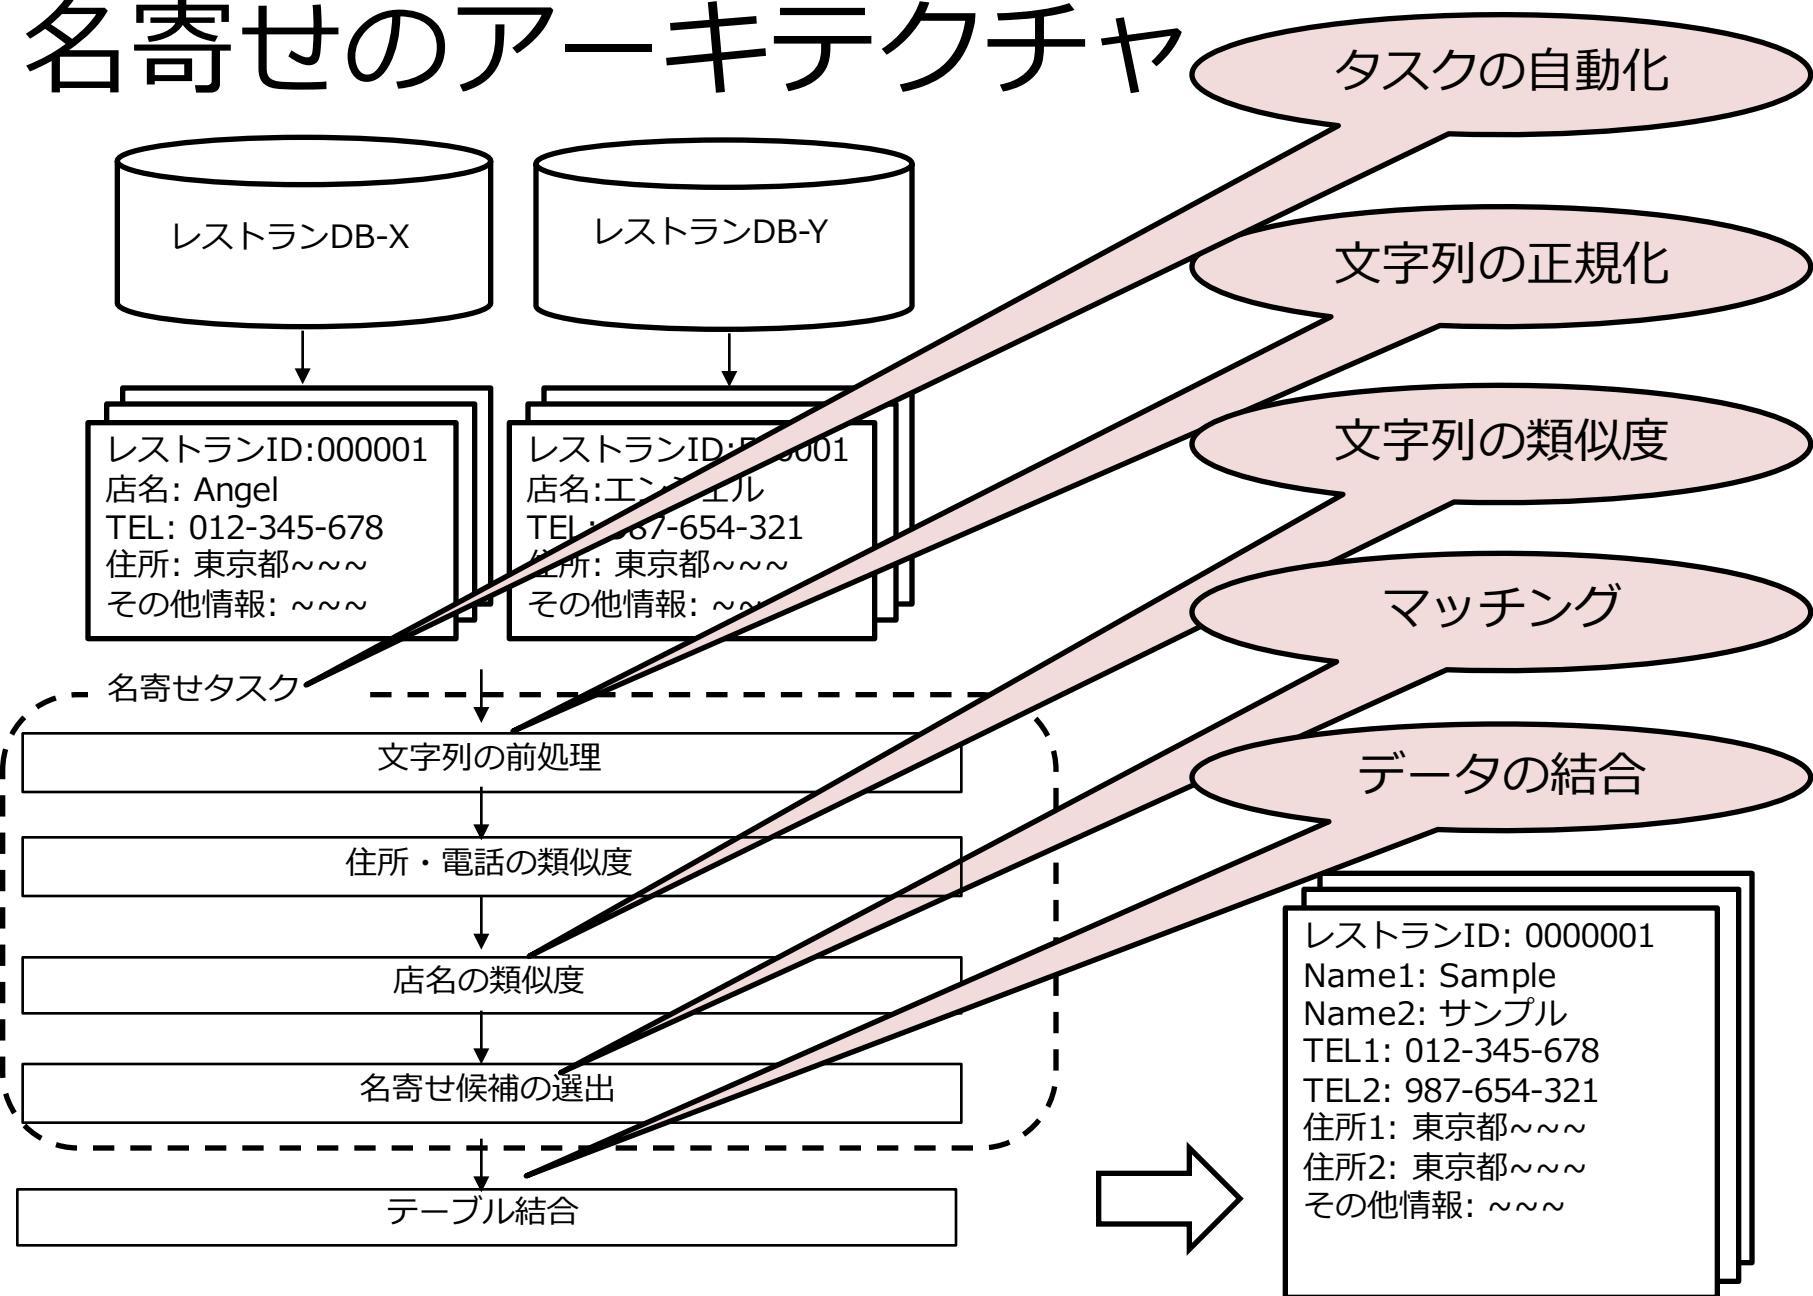
名寄せしたいが…

人手で辞書をつくるのは面倒…

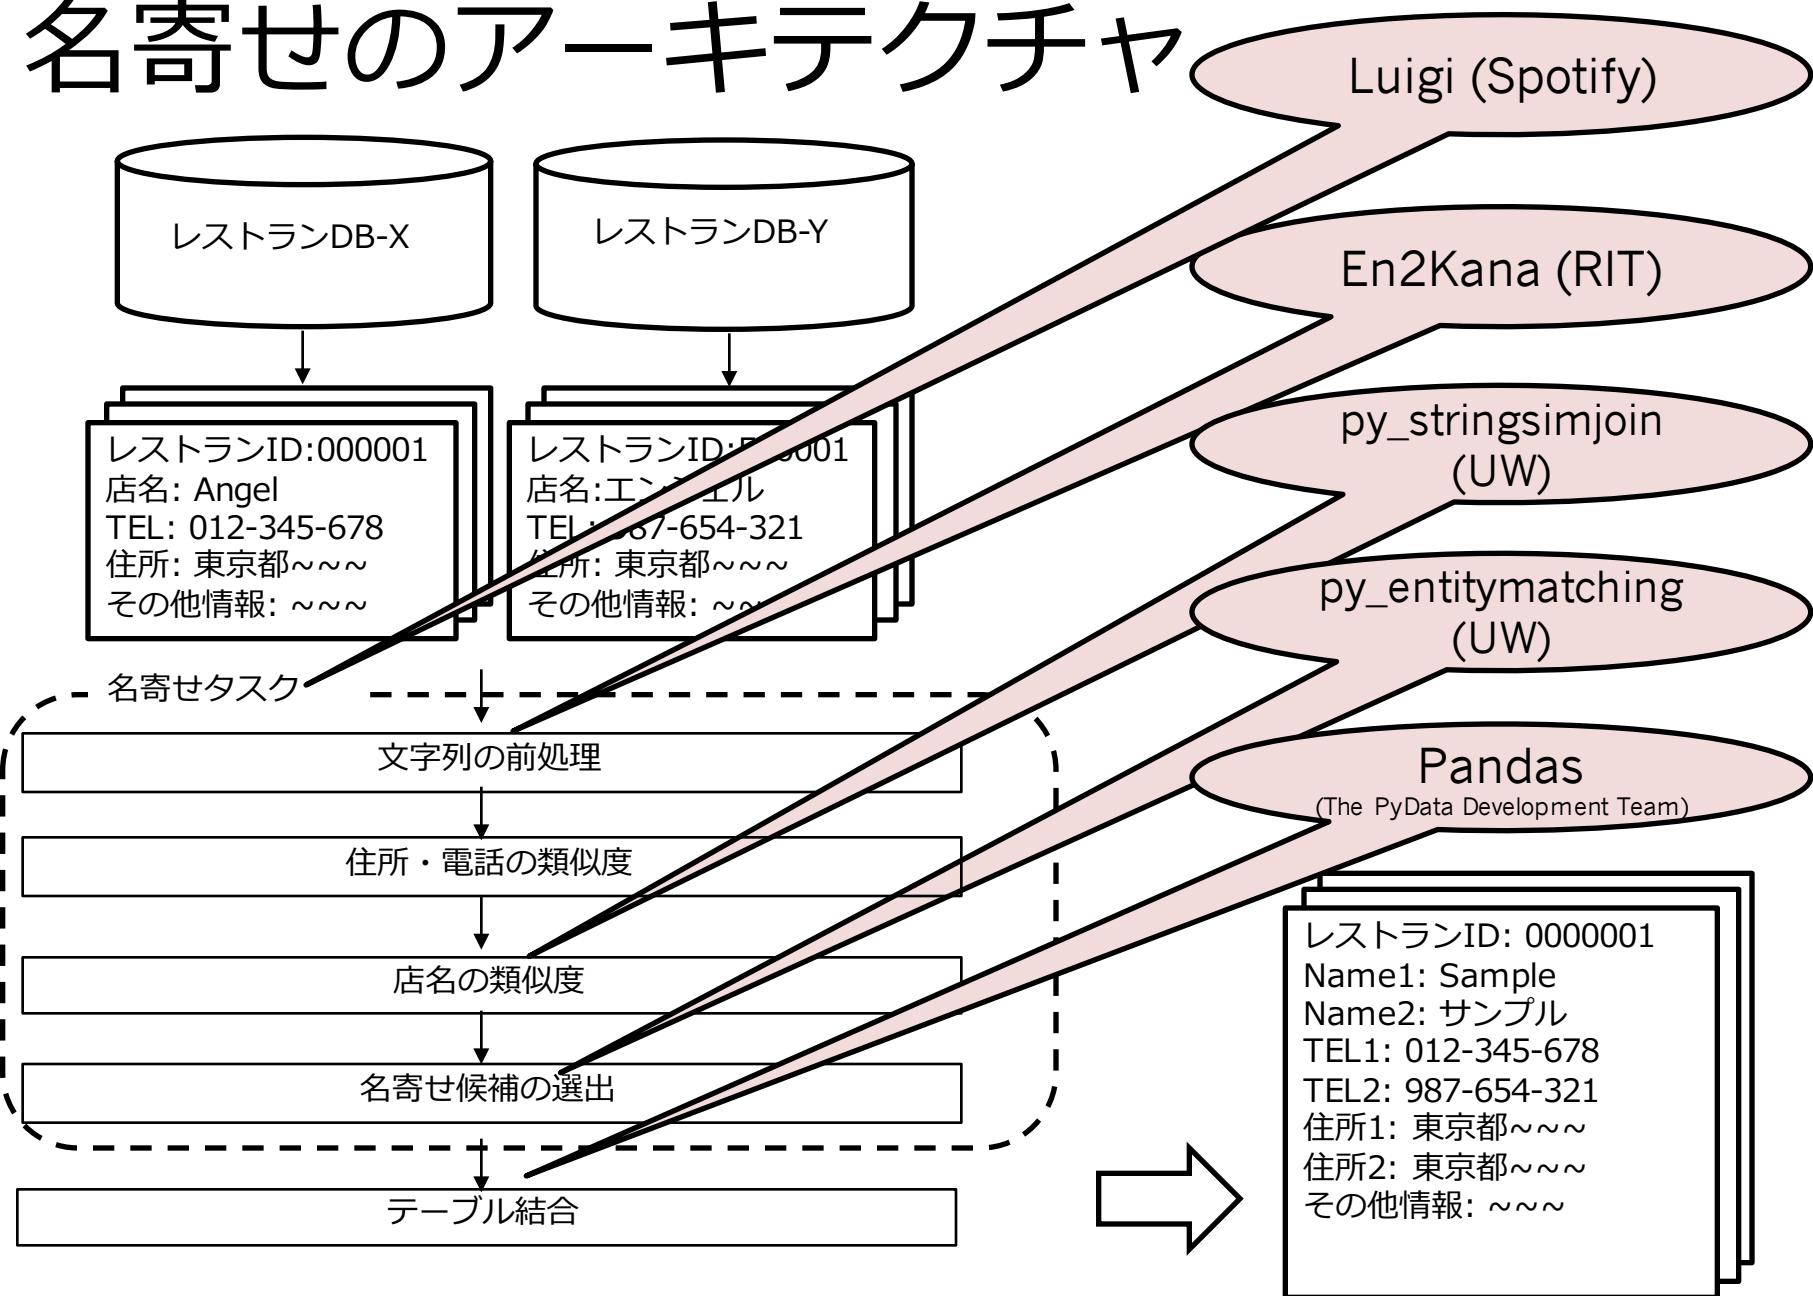
名寄せのアーキテクチャ



名寄せのアーキテクチャ



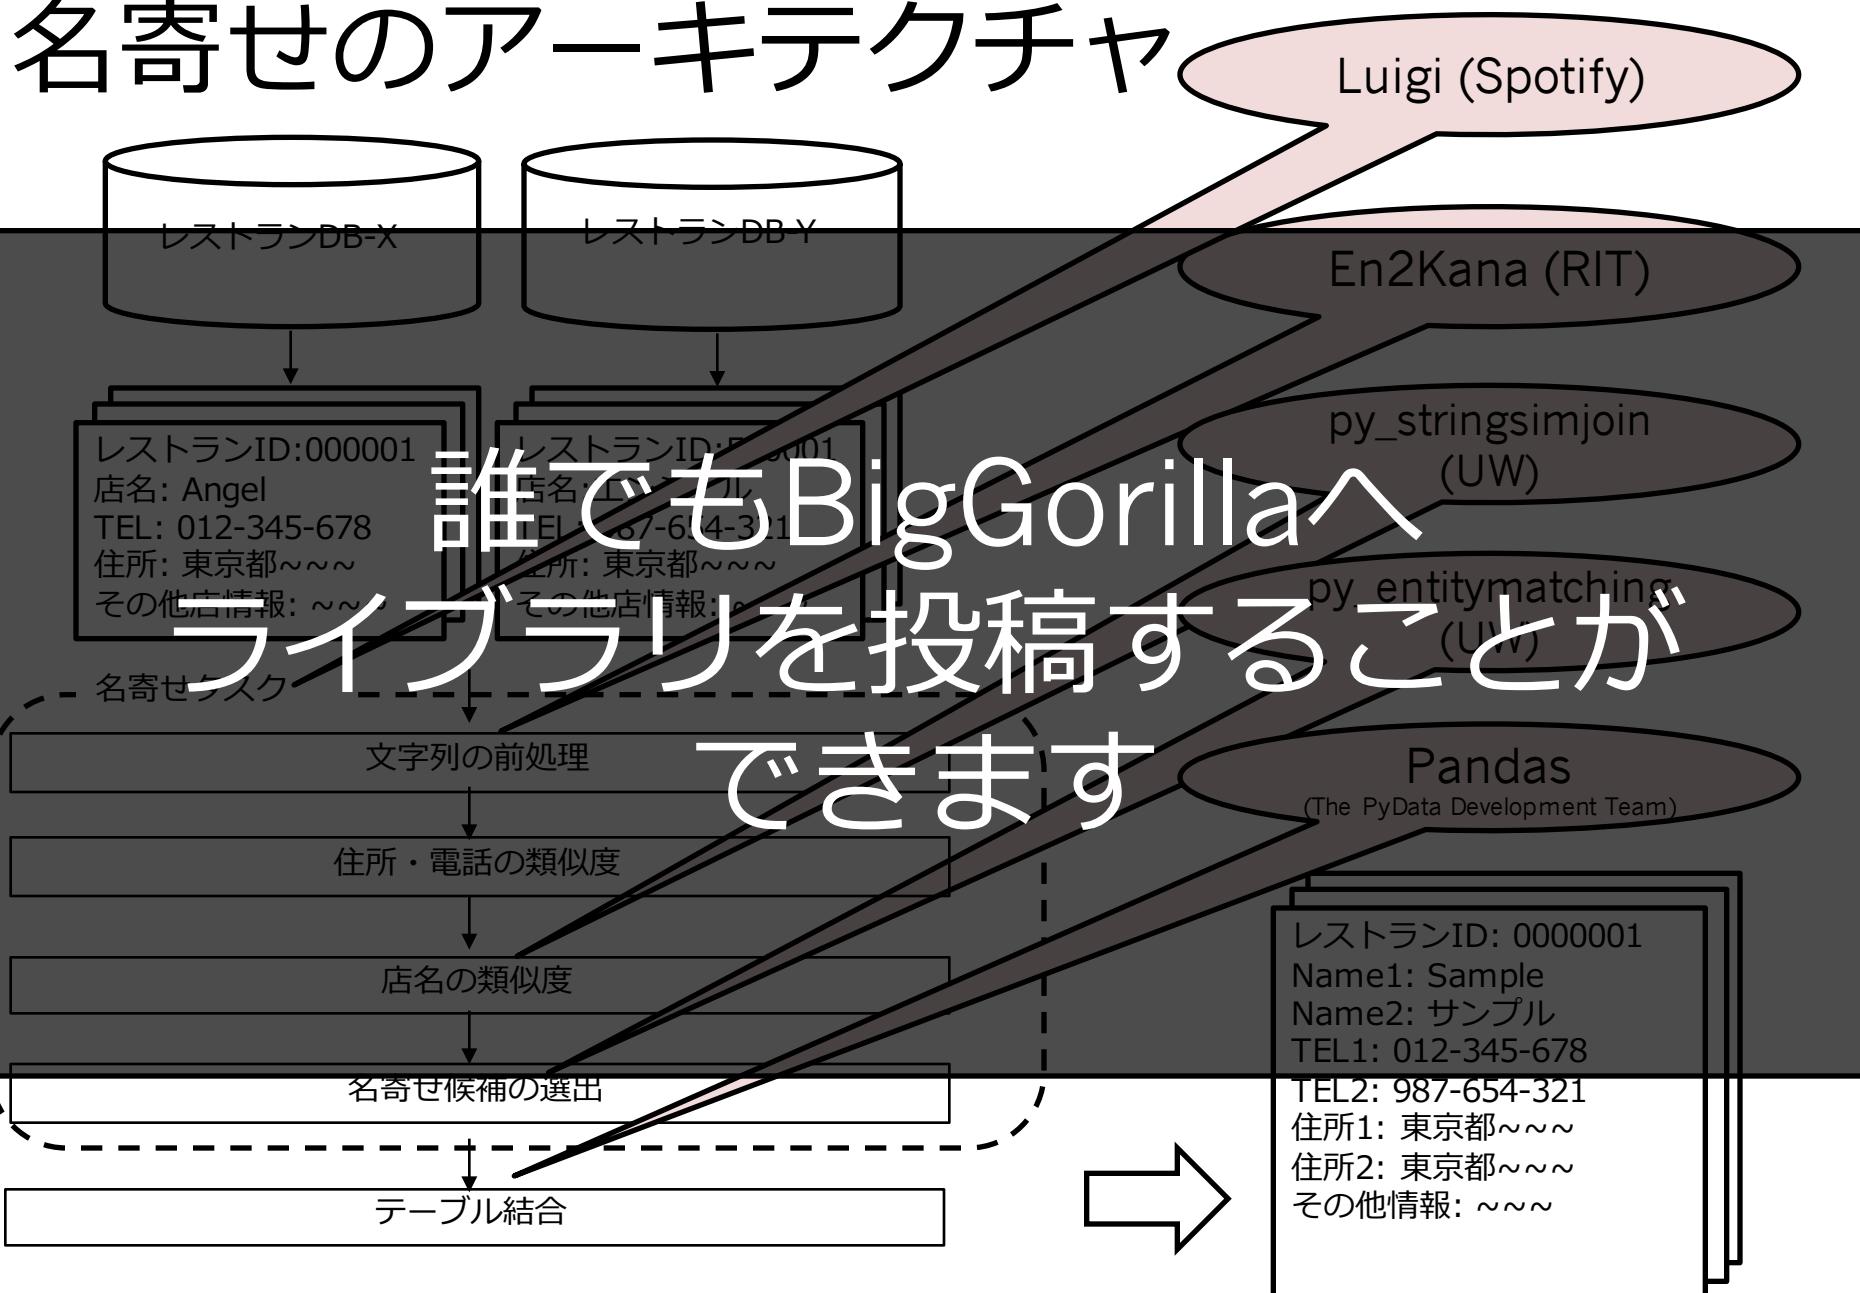
名寄せのアーキテクチャ



名寄せのアーキテクチャ



名寄せのアーキテクチャ



En2Kana: 英語とカタカナの表記揺れを解決するモジュール

発音データを追加で用いることで
文字情報のみでも名寄せが可能に



発音	発音に準じたカタカナ	(参考:ローマ字読み)
éɪndʒəl	エインジェル	エンジェル

En2Kana: 英語とカタカナの表記揺れを解決するモジュール

発音データを追加で用いることで
文字情報のみでも名寄せが可能に

英字表記
Angel

カタカナ表記
エンジェル

発音	発音に準じたカタカナ	(参考:ローマ字読み)
éɪndʒəl	エインジェル	エンジェル

深層学習またはルール
により発音記号へ変換

ルールベースで
カタカナに変換

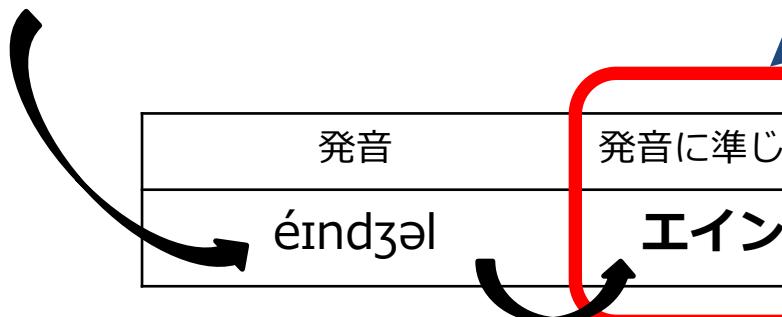
En2Kana: 英語とカタカナの表記揺れを解決するモジュール

発音データを追加で用いることで
文字情報のみでも名寄せが可能に

英字表記
Angel

ここで名寄せ →

カタカナ表記
エンジェル



テーブル名寄せの効果・影響

- 発音情報がないときよりも**10%以上の精度改善**
- 英語とカタカナの表記揺れの多い
10万件以上のデータテーブルを結合可能に
- レストラン名だけでなく
美容院名・会社名・人名・商品名など
他ドメインへも適用可能
- サーチエンジンのクエリ改善にも

BigGorilla その他のライブラリ

BigGorilla:

データの前処理問題を解決するための
知識共有を目指したオープンコミュニティ

ライブラリ例:

Usagi: メタデータの検索、管理

KOKO: テキストデータから欲しい情報を抽出

他にも現在約**30**個のライブラリが集積

(いつでも投稿お待ちしております)

BigGorillaへのコントリビューション

1. ライブラリの紹介

既存のものでも自作でもOK

データの前処理に必要なものをご共有ください

2. 活用事例・ユースケースの紹介

どのような方法でどのような前処理問題を解決したか

このような事例があったのでシェアしたいなど

資料、ドキュメント、コード等をご共有ください

3. フォーラムへの投稿（意見・質問）

こういう前処理の問題で困っている

こんな活用方法もあったなど

BigGorillaへのコントリビューション

1. ライブラリの紹介

既存のものでも自作でもOK

データの前処理に必要なものをご共有ください

2. 活用事例（データ前処理の問題を一緒に解決しませんか？）

どのような前処理を活用ですか？

どのような前処理問題を解決したか等の

事例やコードをご共有ください

3. フォーラムへの投稿（意見・質問）

こういう前処理の問題で困っている

こんな解決方法もあったなど