

地方公共団体の  
オープンデータ取組支援ツールの  
実現可能性調査

調査報告書（詳細版）



tonoi 株式会社

## 目次

1. 本書の位置づけ	4
2. 調査目的	4
3. 調査範囲	4
3.1. 現状調査	5
3.2. 技術調査	5
3.3. 適用可能性評価	6
3.4. プロトタイプの開発	6
3.5. 地方公共団体での実証	6
4. 調査の全体スケジュール	6
4.1. スケジュール概要	6
4.2. 現状調査期間	6
4.3. 技術調査期間	6
4.4. 適用可能性評価期間	6
4.5. プロトタイプの開発期間	7
4.6. 地方公共団体での実証期間	7
4.7. 実施スケジュール	7
5. 現状調査	8
5.1. ヒアリング概要	8
5.2. 質問事項と回答	8
5.3. ヒアリング結果	8
5.3.1. 現状	8
5.3.2. 環境	8
5.3.3. オープンデータ作成のワークフロー	9
5.3.4. データ形式	9
5.3.5. ニーズ	9
5.3.6. 生成 AI	9
6. 技術調査	10
6.1. 調査内容	10
6.2. 実施ステップ	10
6.2.1. 生成 AI 等調査環境	10
6.2.2. 多様なファイル形式	10
6.2.3. レイアウトの整形	12
6.2.4. 地方公共団体での利用可能性	13
6.2.5. 総合評価	13
6.3. 調査結果	14

6.3.1. Tableau prep .....	14
6.3.2. Azure + GPT4 .....	16
6.3.3. ChatGPT Plus .....	18
6.3.4. Bedrock + Claude 2.1 .....	20
6.3.5. Gemini Pro .....	22
6.3.6. LLaMA .....	24
6.3.7. 画像認識によるデータ整形 .....	26
6.4. 技術調査による考察 .....	29
7. 適用可能性評価 .....	30
7.1. 調査内容 .....	30
7.2. 実施ステップ .....	31
7.2.1. ファイル添付方法 .....	31
7.3. 評価結果 .....	31
7.3.1. 有用なプロンプト .....	31
7.3.2. API 呼び出しにおけるハルシネーション .....	35
7.3.3. 文字化け .....	36
7.3.4. BOM 無し CSV ファイル .....	36
7.4. 適用可能性評価による考察 .....	36
8. プロトタイプ開発 .....	37
8.1. プロトタイプシステム詳細 .....	37
8.1.1. フロントアプリ .....	38
8.1.2. データ変換用仮想環境 (Docker-Python) .....	41
8.1.3. データ補完用サービス (Proxy API) .....	41
8.1.4. プロトタイプで利用したサービス .....	41
8.1.5. 生成 AI 本体 .....	43
8.1.6. バックエンド .....	43
8.2. プロトタイプ開発を通して .....	44
9. 実証実験 .....	45
9.1. 実証実験概要 .....	45
9.2. 実証実験のヒアリング結果 .....	45
9.3. 実証実験の結論 .....	46
10. 本調査を通したまとめ .....	47

## 1. 本書の位置づけ

本書は、令和 5 年度デジタル庁「地方公共団体のオープンデータ取組支援ツールの実現可能性調査」の仕様書に基づき、受託者である tonoi 株式会社が実施した調査研究に係る最終報告書である。なお、本調査研究は、令和 5 年 12 月 18 日から令和 6 年 2 月 29 日にかけて実施したものであり、生成 AI の分野は急速に進化していることから、最新の技術情報とは異なる可能性があることに留意していただきたい。

## 2. 調査目的

令和 5 年 6 月 9 日に閣議決定された「デジタル社会の実現に向けた重点計画」1)に掲げられている通り、「オープンデータ基本指針」2)について、社会環境等の変化に対応した内容への見直しが求められている。本事業は、オープンデータを作成する作業支援のために、生成 AI を初めとする社会環境や技術動向等を踏まえた上でのツール開発・提供の有効性を調査研究するものである。

地方公共団体のオープンデータの取り組みは、既存のデータの多種多様性によって、オープンデータへの変換に人手がかかるうえ、専任の担当者がいないケースも多いことから、自治体標準オープンデータセット 3) へのフォーマット変換や、継続したデータ公開を行うことが難しいという問題がある。本調査では地方公共団体の実状に応じた支援策を検討するために、生成 AI や従来の機械学習のツールなどを使うことで、データ変換にかかる作業簡略化の可能性の調査を行い、更なるオープンデータの取り組み推進およびデータの質の向上につなげることを目的とする。

### 1) デジタル社会の実現に向けた重点計画

[https://www.digital.go.jp/assets/contents/node/basic\\_page/field\\_ref\\_resources/5ecac8cc-50f1-4168-b989.2bcaabffe870/86978bc6.20230609\\_policies\\_priority\\_outline\\_06.docx](https://www.digital.go.jp/assets/contents/node/basic_page/field_ref_resources/5ecac8cc-50f1-4168-b989.2bcaabffe870/86978bc6.20230609_policies_priority_outline_06.docx)

### 2) オープンデータ基本指針

[https://www.digital.go.jp/assets/contents/node/basic\\_page/field\\_ref\\_resources/f7fde41d-ffca-4b2a-9b25-94b8a701a037.20210615\\_resources\\_data\\_guideline\\_01.pdf](https://www.digital.go.jp/assets/contents/node/basic_page/field_ref_resources/f7fde41d-ffca-4b2a-9b25-94b8a701a037.20210615_resources_data_guideline_01.pdf)

### 3) 自治体標準オープンデータセット

[https://www.digital.go.jp/resources/open\\_data/municipal-standard-data-set-test](https://www.digital.go.jp/resources/open_data/municipal-standard-data-set-test)

## 3. 調査範囲

本調査では下記について調査研究を実施した。

地方公共団体におけるオープンデータの取り組み作業の負荷軽減を目的として、現在、オープンデータ作成の元となっている既存の表形式のスプレッドシートや PDF のファイルから、自治体

標準オープンデータセット(以後、「自治体標準 ODS」と略記)の CSV ファイル等への変換作業を支援するツールのプロトタイプを開発し、その実現可能性を調査した。

具体的には、データフォーマットの変換作業を支援できるシステムの構築が可能であるか、その周辺技術である生成 AI や従来の機械学習の手法の調査、およびシステムのプロトタイプを実際に地方公共団体で使用していただき、作業負荷の軽減と作業自体の効率化の調査・検証を行った。

### 3.1. 現状調査

地方公共団体の現状を把握するため、以下の観点より 3 つの地方公共団体をピックアップしてヒアリング調査を行い現状を分析した。

(ア)人口規模

(イ)広域と基礎自治体の組み合わせ

(ウ)オープンデータの取り組み度合いの組み合わせ

ヒアリング調査においては事前に作成した質問項目に従って回答を得た。また、適用可能性評価のために必要な変換元データの提供を依頼した(表 1)。

表 1: ヒアリング対象の地方公共団体

類型	人口	オープンデータ 公開場所	公開数
小規模基礎自治体	約 3.4 万人	地方公共団体サイト内	2
中規模基礎自治体	約 30 万人	外部サイト	208
都道府県	約 350 万人	内部専用サイト	3361

### 3.2. 技術調査

データ変換作業支援に有用な生成 AI と、それが動作する環境やサービス、API などに関する合目的性の調査を行った。

特に技術的な側面として、以下の 3 点を調査し、総合的な評価を行った(別紙表 28 参照)。

1. 多様なファイルフォーマットに対応可能か
  - スプレッドシート、PDF、ZIP
2. 複雑なレイアウトに対応可能か
  - タイトルページの読み飛ばし、複数表の混載、グラフとの混載、縦組み、外字処理等
3. 地方公共団体での利用に適しているか
  - クラウド環境かローカル環境か、ファイル削除は正常か、通信の秘匿性は保証されているか、処理中のデータは外部から見られないのか、アカウント管理の安全性等

### 3.3. 適用可能性評価

地方公共団体へのヒアリングを通して得られた元データを使用し、自治体標準 ODS に変換できるか実際にツールを使って検証を行った。

地方公共団体より提供された元データで検証できない項目に関しては独自にデータを作成して調査した。補完対象項目については工数と期間を勘案し、デジタル庁と協議の上、POI コード、法人番号、URL に関しては評価対象外とすることとした。(別紙表 29 参照)。

### 3.4. プロトタイプの開発

技術調査・適用可能性評価の結果をもとに地方公共団体職員による利用を想定したシステムのプロトタイプを構築した。自治体標準 ODS を作成する元となるデータには機密情報等が含まれている可能性があるため、隔離されたローカル環境での構築が望ましい。しかしながら、技術調査の結果現時点で実用性の高い生成 AI はクラウド環境が必須であることが確認できたため、クラウド上に閉鎖環境を作り、そこにプロトタイプシステムを構築した。

### 3.5. 地方公共団体での実証

プロトタイプシステム上で、ヒアリング対象となった地方公共団体の職員に提供された元データを自治体標準 ODS に変換する操作を行っていただき、検証するツールが自治体標準 ODS 作成業務において有効かを調査した。

## 4. 調査の全体スケジュール

### 4.1. スケジュール概要

納期を踏まえて実証実験開始を令和 6 年 2 月初めと設定し、既存の資産を流用しつつ一部の調査を並行して実施する形で全体のスケジュールを立て、得られた知見を適時に他の工程へも反映させることでデジタル庁の承認を得た。

### 4.2. 現状調査期間

令和 5 年 12 月 18 日から 22 日にかけて、各地方公共団体に訪問してヒアリングを行った。

### 4.3. 技術調査期間

令和 5 年 12 月 15 日から令和 6 年 1 月 22 日にかけて、各ツールの技術調査を行った。ただし、地方公共団体からのヒアリング結果のまとめがずれ込んだため、先行して一部地方公共団体より提供されたデータを使用した技術調査を行い、その後、ヒアリング調査結果を受け、各地方公共団体より提供されたデータをもとに追検証を行う形とした。

### 4.4. 適用可能性評価期間

令和 5 年 12 月 22 日から令和 6 年 1 月 29 日にかけて、地方公共団体より提供されたデータを使用し、自治体標準 ODS への変換・整形を確認する適用可能性評価を行った。

#### 4.5. プロトタイプの開発期間

令和5年12月15日から令和6年1月29日にかけて、自治体標準 ODS ヘデータ変換を行うシステムのプロトタイプを開発した。

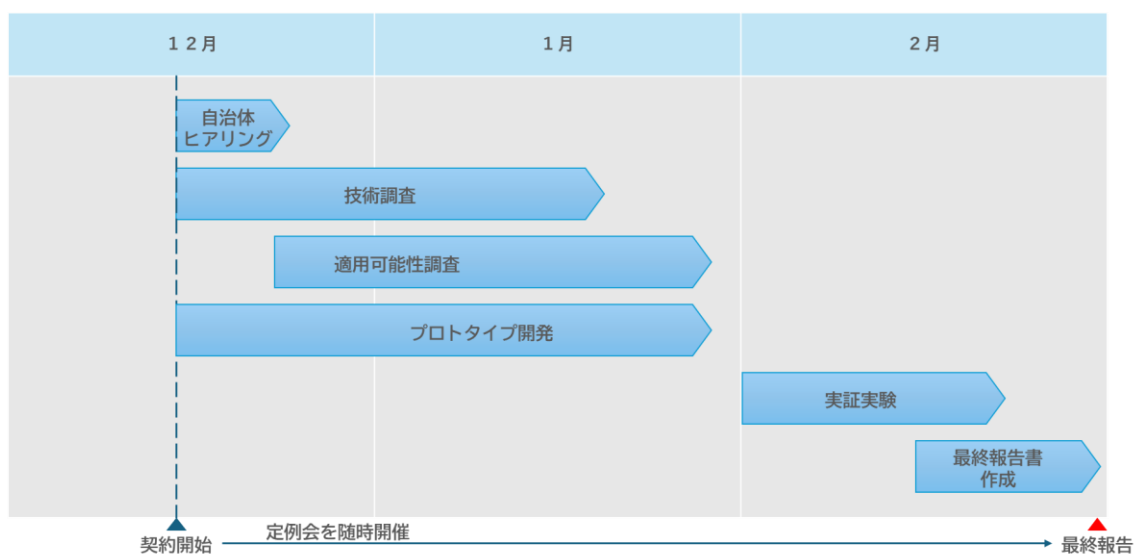
#### 4.6. 地方公共団体での実証期間

開発したプロトタイプを使用して令和6年2月1日から同年2月22日にかけて、データ変換の実証実験を行った。

#### 4.7. 実施スケジュール

スケジュールの概要を図1に示す。

図1：実証実験実施スケジュール



## 5. 現状調査

### 5.1. ヒアリング概要

本調査を行う上で、まずは人口規模や自治体標準 ODS への取り組み状況の異なる 3 か所の地方公共団体を選定し、通常業務でどのような種類のデータがどのようなフォーマットで作成されているかを確認した。その際、自治体標準 ODS への整形手順などを、実際に作業を担当している課の職員、担当者にヒアリングを行い、データ変換時の問題点の洗い出しを行った。

### 5.2. 質問事項と回答

ヒアリングは 6 つの論点に分け、各論点に対して確認事項を設定し、質問を行った（表 2）。

表 2：ヒアリングの質問項目

1. オープンデータの現状 (ア) 認知度 (イ) 統合計画 (ウ) 具体的な取り組み (エ) 活用実例創出 (オ) 課題 (カ) 今後の取り組み	2. 自治体標準オープンデータセット (ア) 認知度 (イ) 取り組み (ウ) 新たな種類 (エ) 意見・要望	3. データ作成と公開 (ア) 作成 (イ) 元データ (ウ) 変換フロー (エ) 意見・要望
4. 利用環境、支援ツール (ア) Web サービス (イ) ソフトウェア (ウ) 生成 AI (エ) クレンジング (オ) ニーズ (カ) 環境	5. 実証用データ (ア) HTML (イ) データ作成手段 (ウ) その他	6. その他 (ア) 人材育成 (イ) デジタル庁の施策 (ウ) その他追加事項

ヒアリング項目の詳細は別紙表 31 を参照のこと。

### 5.3. ヒアリング結果

#### 5.3.1. 現状

自治体標準 ODS 作成への取り組みは地方公共団体ごとに違いが見られた。取組への動機が明確ではない場合、徐々に失速してしまう傾向が見られた。一方、自発的に自治体標準 ODS を作成する地方公共団体では 3 次元点群情報の利用、ハッカソンやラウンドテーブル、不動産業での活用などオープンデータが有効活用されていた。

#### 5.3.2. 環境

3 つの地方公共団体でヒアリングを実施したが、IT 環境は統一されておらず、地方公共団体ごとのみならずケースによっては課ごとに異なるツール群・ネットワーク環境を使用していた。地方公共団体職員からは年間予算が組みやすい買い切り型のインストールできる単一アプリケーションの要望もあった。表計算ソフトとしてはマイクロソフト社の Excel が中心だがジャストシステム社の JUST Calc も一部で利用されていた。また、ネットワーク環境としては、3 層分離により利用できないサービスがあることも問題となっていた。



### 5.3.3. オープンデータ作成のワークフロー

自治体標準 ODS への対応が進んでいる都道府県では 1) すべての市町村が公開可能な状態まで整形したデータを作成、2) 所管課が公開用 CMS に登録、3) 作成した市町村に確認、4) 公開 という手順をとっている。すべての市町村に CMS のアカウントを作成して配布することで市町村がオープンデータ作成可能となった。

自治体標準 ODS への取組が中程度の地方公共団体では、地方公共団体の IT 処理を一部外部委託しており、オープンデータ作成もその一環で外部委託している。情報システム部門が集めてきた元データを委託事業者へ渡し、委託事業者がオープンデータ作成と公開を担う。公開前に情報システム部門が仲介して原課に問題ないか確認している。また、原課に紙の地図でしか情報がない消火栓の位置などは情報システム部門が地図を読み取って手入力で機械判読可能なデータを作成していた。

自治体標準 ODS への対応がこれからの地方公共団体では、情報システム部門の職員が手作業でオープンデータ作成を行い、地方公共団体の Web サイトにて公開している。元データもないものが多く、施設の情報などは各施設の Web サイトを目で見てデータ作成を行った。オープンデータとすべき元データは調書として紙でファイリングされているため、調書のデータを支援ツールで抽出できれば良いが、縦組みや施設ごとに 1 ページが使われる表形式ではないものとなり機械判読可能なデータ化が困難である (表 3)。

表 3：オープンデータ作成のワークフロー

比較項目	小規模基礎自治体	中規模基礎自治体	都道府県
元データの発生源	情報システム部門員の手作業	情報システム部門が原課から入手	各市町村が作成
データ整形の担当	情報システム部門員の手作業	外部委託	各市町村が整形
データの公開サイトへの登録	情報システム部門員の手作業	外部委託	デジタル課が登録
公開データの管理	情報システム部門員の手作業	外部委託	専用 CMS
データ公開前のチェック担当	原課	原課	各市町村
公開場所	地方公共団体サイト内	専用サイト(CKAN)	専用サイト(Shirasagi)

### 5.3.4. データ形式

地方公共団体職員が自身でデータ変換を行う場合は Excel でデータを用意し、委託事業者や他の課にデータ処理を依頼する場合は PDF を利用する傾向が見られた。

### 5.3.5. ニーズ

原課の元データを自治体標準 ODS に変換するには項目が不足していることが多くみられ、不足項目の内容を検索したり補完したりする機能に強いニーズがあった。

### 5.3.6. 生成 AI

申請ベースだが、ガイドラインを設けて使っていこうという積極性が見られる地方公共団体もあった。

## 6. 技術調査

自治体標準 ODS への変換支援に使えるツール・技術を選定するための事前の技術調査を実施。データ変換の技術要素に加え、地方公共団体での利用可能性も比較検討した。

### 6.1. 調査内容

地方公共団体より提供された元データから 3.2. 章に掲げた調査に活用できるデータを選出し、サービスや Web アプリの調査を行った。該当するデータが存在しない場合は新たにデータを作成して対応した。

### 6.2. 実施ステップ

#### 6.2.1. 生成 AI 等調査環境

Tableau は Tableau Cloud を契約し、サーバーサービスを用いてデータ整形を行った。

生成 AI はオープン環境ではチャット画面が用意されておりファイル添付も可能だが、本調査では閉鎖環境で実施する必要があるため、独自のプログラム開発を行い、閉鎖環境を準備した。また調査対象のクラウドに「Playground」という閉鎖環境でのチャットを試す UI が用意されているが、そこにはファイル添付ができずデータ整形を行えない。そのため、OpenAI 系のサービスに関しては開発中のプロトタイプから各生成 AI に接続して検証を行った。

- Bedrock : Knowledge base という RAG (Retrieval Augmented Generation) でファイルの解析や Python で直接 API を呼び出し、検証を行った。
- Gemini : Jupyter Notebook で Python プログラムを作成し、直接 API を呼び出し、検証を行った。
- LLaMA : Jupyter Notebook を用いて検証を行った。

生成 AI の調査にはクラウド環境の構築とそこで動くアプリケーションの開発が必要であるが、実際に地方公共団体職員が支援ツールとして生成 AI を使う場合も同様のアプリケーションが必要であり、単なる生成 AI の性能測定にとどまらない実態調査となると考えた。

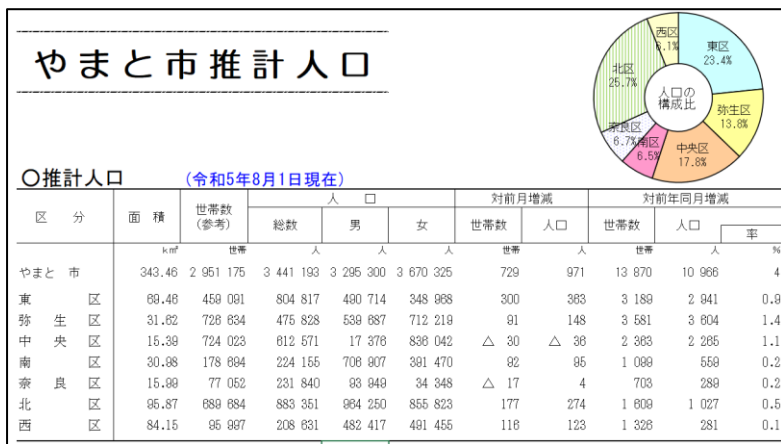
#### 6.2.2. 多様なファイル形式

サービスや Web アプリに読み込ませて調査に使用したファイルを表 4 に示す。

表 4 : 調査用ファイルフォーマット

フォーマット	内容	参考図
スプレッドシート	セル結合・縦組み・横組みが混在する表や円グラフで構成されたシート	図 2
PDF	同一ページに複数の表がある PDF	図 3
ZIP ファイル	Unicode で保存された CSV 形式のテキストを ZIP で圧縮したファイル	図 4
文字コード別テキスト	上記のテキストを、Unicode 以外 (JIS, SJIS, EUC) の文字コードで保存した個別ファイル	図 5
PDF	読み飛ばすページを含む PDF	図 6
外字混在テキスト	外字を含むテキストファイル	図 7

図 2：スプレッドシート（グラフの混載. xlsx）



実際のデータを元に仮想データを作成して記載

図 3：PDF（同一ページに複数の表.pdf）

名称	名称_カナ	郵便番号	住所	電話番号
やまと市庁舎	ヤマトシチョウシヤ	999-0001	大和県やまと市城町12-5	00-4136-5170
やまと市生涯学習センター	ヤマトシヨウガイガクシュウセンター	999-0002	大和県やまと市中央区原町3-4	00-8328-3358
南部保健福祉センター	ナンブホケンフクシセンター	999-0003	大和県やまと市南区山田3-23	00-2704-2185
やまと市文化ホール	ヤマトシブンカホール	999-0004	大和県やまと市中央区城町2-34	00-1036-1348
市民活動サポートハート	シミンカドウサポートハート	999-0005	大和県やまと市中央区中央町1-23-2	00-1367-4150
やまとグリーンセンター	ヤマトグリーンセンター	999-0006	大和県やまと市東区野中3-1	00-9117-1363
やまと市美術館	ヤマトシビジュツカン	999-0007	大和県やまと市南区津2-1	00-3008-2168
やまと市博物館	ヤマトシハクブツカン	999-0008	大和県やまと市北区浜町2-1-2	00-3467-6744
やまと市総合図書館	ヤマトシソウゴウトシヨカン	999-0009	大和県やまと市中央区1-1-1	00-9556-6431

名称	名称_カナ	郵便番号	住所	電話番号
中央区市民センター	チュウオウクシミンセンター	999-0001	大和県やまと市中央区城町1-31-3	00-9234-7284
北區市民センター	キタクシミンセンター	999-0002	大和県やまと市北区浜町5-23-2	00-4398-4299
東区市民センター	ヒガシクシミンセンター	999-0003	大和県やまと市東区中町8-1	00-4570-8006
南区市民センター	ミナミクシミンセンター	999-0004	大和県やまと市南区南条2-12	00-1242-5187
西区市民センター	ニシクシミンセンター	999-0005	大和県やまと市西区大城23-4	00-2335-6383
中央区コミュニティセンター	チュウオウクコミュニティセンター	999-0006	大和県やまと市中央区中央町2-3-38	00-4995-2279
北區コミュニティセンター	キタクコミュニティセンター	999-0007	大和県やまと市長浜町2-3-6	00-6231-1149
東区コミュニティセンター	ヒガシクコミュニティセンター	999-0008	大和県やまと市東区城崎町2-4-5	00-4556-4876
南区コミュニティセンター	ミナミクコミュニティセンター	999-0009	大和県やまと市南区山本3-2-4	00-3939-3510
西区コミュニティセンター	ニシクコミュニティセンター	999-0010	大和県やまと市北野2-1-2	00-7849-2120

実際のデータを元に仮想データを作成して記載

図 4：ZIP ファイル（公共施設.zip）

公共施設.zip
➔
解凍

都道府県	市区町村	名称	名称_カナ	名称_英語	POIコード	住所	方量	緯度	経度	電話番号	内線番号
1	大和県	やまと市	やまと市庁舎	ヤマトシチョウシヤ	13512a	大和県やまと市城町12-5	35.83184	139.639	03-4136-5170		
2	大和県	やまと市	やまと市生涯学習センター	ヤマトシヨウガイガクシュウセンター	0803a	大和県やまと市中央区原町3-4	35.66757	139.7847	03-8328-3358		
3	大和県	やまと市	南部保健福祉センター	ナンブホケンフクシセンター	1320a	大和県やまと市南区山田3-23	35.68931	139.8846	03-2704-2185		
4	大和県	やまと市	やまと市文化ホール	ヤマトシブンカホール	1157a	大和県やまと市中央区城町2-34	35.80938	139.6306	03-1036-1348		
5	大和県	やまと市	市民活動サポートハート	シミンカドウサポートハート	1199a	大和県やまと市中央区中央町1-23-2	35.11241	139.7853	03-1367-4150		
6	大和県	やまと市	やまとグリーンセンター	ヤマトグリーンセンター	1499a	大和県やまと市東区野中3-1	35.92875	139.6448	03-9117-1363		
7	大和県	やまと市	やまと市美術館	ヤマトシビジュツカン	1499a	大和県やまと市南区津2-1	35.81184	139.7393	03-3008-2168		
8	大和県	やまと市	やまと市博物館	ヤマトシハクブツカン	1499a	大和県やまと市北区浜町2-1-2	35.22225	139.7737	03-3467-6744		
9	大和県	やまと市	やまと市総合図書館	ヤマトシソウゴウトシヨカン	1499a	大和県やまと市中央区1-1-1	35.66293	139.6988	03-9556-6431		
10	大和県	やまと市	中央区市民センター	チュウオウクシミンセンター	1499a	大和県やまと市中央区城町1-31-3	35.86293	139.6273	03-9234-7284		
11	大和県	やまと市	北區市民センター	キタクシミンセンター	1499a	大和県やまと市北区浜町5-23-2	35.88835	139.7883	03-4398-4299		
12	大和県	やまと市	東区市民センター	ヒガシクシミンセンター	1499a	大和県やまと市東区中町8-1	35.48393	139.6353	03-4570-8006		
13	大和県	やまと市	南区市民センター	ミナミクシミンセンター	1499a	大和県やまと市南区南条2-12	35.59986	139.6593	03-1242-5187		
14	大和県	やまと市	西区市民センター	ニシクシミンセンター	1499a	大和県やまと市西区大城23-4	35.85982	139.681	03-2335-6383		
15	大和県	やまと市	中央区コミュニティセンター	チュウオウクコミュニティセンター	1454a	大和県やまと市中央区中央町2-3-38	35.98742	139.5322	03-4995-2279		
16	大和県	やまと市	北區コミュニティセンター	キタクコミュニティセンター	1003a	大和県やまと市長浜町2-3-6	35.84445	139.6593	03-6231-1149		
17	大和県	やまと市	東区コミュニティセンター	ヒガシクコミュニティセンター	1003a	大和県やまと市東区城崎町2-4-5	35.43963	139.6235	03-4556-4876		

公共施設.CSV

実際のデータを元に仮想データを作成して記載

図 5：テキストファイル（EUC.csv、JIS.csv、SJIS.csv）

```

都道府県コード又は市区町村コード、NO. 都道府県名、市区町村名、名称、名称カナ、名称通称、P01コード、住所、方書、緯度、経度、電話番号、内線番号、法人番号、団体名、利用可能曜日、
開始時間、終了時間、利用可能時間特記事項、説明、バリアフリー情報、URL、備考
127077.1. 大和県、やまと市、やまと市庁舎、ヤマトシチョウシヤ、.1512a、大和県やまと市城町12-5、.35.83183763,139.6389743,03-4136-5170、.7120020000101
127077.2. 大和県、やまと市、やまと市生涯学習センター、ヤマトシヨウガイグシユセンター、.0803a、大和県やまと市中央区原町3-4、.35.66757412,139.7846539,03-8328-
3358、.596002387000
127077.3. 大和県、やまと市、南部保健福祉センター、ナンブホケンフクシセンター、.1308a、大和県やまと市南区山田3-23、.35.68983274,139.8946482,03-2704-2185、.8710280046001
127077.4. 大和県、やまと市、やまと市文化ホール、ヤマトシブンカホール、.1107a、大和県やまと市中央区城町2-34、.35.80938461,139.6306366,03-1036-1348、.8481870345023
127077.5. 大和県、やまと市、市民活動サポートハート、シミンカツドウサポートハート、.1199a、大和県やまと市中央区中央町1-23-2、.35.11240691,139.7853281,03-1367-
4150、.6140003460310
127077.6. 大和県、やまと市、やまとクリーンセンター、ヤマトクリーンセンター、.1499a、大和県やまと市東区野中3-1、.35.92874688,139.6448463,03-9117-1363、.6342876400234
127077.7. 大和県、やまと市、やまと市美術館、ヤマトシビジュツカン、.1499a、大和県やまと市南区津2-1、.35.81184297,139.7393439,03-3008-2168、.1840820297008
127077.8. 大和県、やまと市、やまと市博物館、ヤマトシハクブツカン、.1499a、大和県やまと市北区浜町2-1-2、.35.2225236,139.7736545,03-3467-6744、.9577650376005
127077.9. 大和県、やまと市、やまと市総合図書館、ヤマトシソウゴウトシヨカン、.1499a、大和県やまと市中央町1-1-1、.35.66292856,139.6987624,03-9556-6431、.9797252009167
127077.10. 大和県、やまと市、中央区市民センター、チュウオウクシミンセンター、.1499a、大和県やまと市中央区城町1-31-3、.35.86292759,139.6272565,03-9234-
7284、.6319373450927
127077.11. 大和県、やまと市、北区市民センター、キタクシミンセンター、.1499a、大和県やまと市北区浜町5-23-2、.35.88834757,139.7983252,03-4398-4299、.8570923746101
127077.12. 大和県、やまと市、東区市民センター、ヒガシクシミンセンター、.1499a、大和県やまと市東区中町8-1、.35.48392852,139.6353221,03-4570-8006、.5000262840955
127077.13. 大和県、やまと市、南区市民センター、ミナミクシミンセンター、.1499a、大和県やまと市南区南条2-12、.35.59986421,139.6592835,03-1242-5187、.6220924678210
127077.14. 大和県、やまと市、西区市民センター、ニシクシミンセンター、.1499a、大和県やまと市西区大城23-4、.35.85982425,139.6809733,03-2335-6383、.6260938461937
127077.15. 大和県、やまと市、中央区コミュニティセンター、チュウオウクコミュニティセンター、.1404a、大和県やまと市中央区中央町2-3-38、.35.98741986,139.5322371,03-4995-
2279、.5230837651271

```

実際のデータを元に仮想データを作成して記載

### 6.2.3. レイアウトの整形

#### 6.2.3.1 ページ飛ばし

タイトルや目次など、先頭の数ページを読み飛ばした後に、データを読み取るページ飛ばしに関しては、以下の PDF ファイル（図 6）を使用し、総ページ数 301 のうち、1 ページ目から 100 ページ目までを読み飛ばせるかを調査した。

図 6：ページ飛ばしの調査に使用した PDF（読み飛ばして画像の AED データ.pdf）

<p>内容</p> <ul style="list-style-type: none"> <li>数値.....3</li> <li>市長からの挨拶.....4</li> <li>副市長からの挨拶.....4</li> <li>行政部門.....7</li> <li>行政の概要.....7</li> <li>主要な事業と成果.....8</li> <li>新しい施策の導入.....9</li> <li>財政概況.....10</li> <li>取組状況.....11</li> <li>予算の編成と分析.....12</li> <li>人事と組織改革.....13</li> <li>市民サービスの向上.....13</li> <li>市民サービスの向上.....14</li> <li>視察サービス.....15</li> <li>市民参加と市民権.....15</li> <li>教育部門.....16</li> <li>教育政策の概要.....17</li> <li>学校教育の概要.....18</li> <li>特別支援教育.....20</li> <li>教育施設の新築状況.....22</li> <li>教育予算の分析.....23</li> <li>社会福祉.....23</li> <li>社会福祉政策.....23</li> <li>高齢者福祉.....25</li> <li>児童福祉.....27</li> <li>障がい者支援.....29</li> <li>生活保護.....30</li> <li>経済部門.....32</li> <li>地域経済の現状.....34</li> <li>産業振興策.....38</li> <li>農業者の支援.....41</li> <li>農林水産業の現状と支援.....46</li> <li>観光振興策.....48</li> </ul>	<ul style="list-style-type: none"> <li>観光客の動向.....52</li> <li>福祉政策.....55</li> <li>福祉関係活動.....58</li> <li>スポーツ政策.....59</li> <li>福祉施設の新築.....63</li> <li>自然保護活動.....66</li> <li>都市計画.....69</li> <li>都市計画の概要.....73</li> <li>道路と交通の概要.....77</li> <li>公園と緑地の概要.....78</li> <li>都市再生プロジェクト.....78</li> <li>防災計画.....80</li> <li>防災と防犯.....82</li> <li>都市政策.....85</li> <li>防災施設の新築.....88</li> <li>感染症対策.....93</li> <li>保健活動の概要.....94</li> <li>文化・スポーツ.....96</li> <li>スポーツ施設の新築.....97</li> <li>地域イベントの概要.....97</li> <li>安全管理.....97</li> <li>公共安全管理.....98</li> <li>防災と救急の活動.....99</li> <li>AED 設置場所一覧表.....100</li> <li>防災対策.....101</li> <li>交通安全対策.....101</li> <li>防災訓練.....102</li> <li>防災交流活動.....103</li> <li>福祉部会との交流.....103</li> <li>防災会議の開催.....104</li> <li>新築計画.....105</li> <li>新築計画の概要と計画.....105</li> <li>データ管理と防災.....106</li> <li>新技術の導入.....106</li> </ul>
--	--

実際のデータを元に仮想データを作成して記載

#### 6.2.3.2 複数の表

ファイルフォーマットの検証で用いた PDF (図 3) を流用。

#### 6.2.3.3 グラフ混載

ファイルフォーマットの検証で用いたスプレッドシート (図 2) を流用。

#### 6.2.3.4 セル結合 (項目)

ファイルフォーマットの検証で用いたスプレッドシート (図 2) を流用。

#### 6.2.3.5 セル結合 (データ)

ファイルフォーマットの検証で用いたスプレッドシート (図 2) を流用。


#### 6.2.3.6 縦組み表混載

ファイルフォーマットの検証で用いた PDF (図 2) を流用。

#### 6.2.3.7 外字処理

①などの丸数字は複数の文字コードがある。Unicode に含まれない SJIS 外字である NEC 特殊文字はマイクロソフト標準キャラクターセットに含まれるため Windows 機では正常に表示されるものの、Mac を含む複数の環境で正しく表示されない (文字化け)。そこで特殊文字でよく使われる文字とアドレスの境界値を含む CSV データを作成し、調査にはこのファイルを使用した (図 7)。

図 7 : 対象外字文字列: 8740h-874Fh, 8790h-879Fh, ED40h-ED4Fh, EEF0h-EEFFh (外字\_SJIS.csv)



#### 6.2.4. 地方公共団体での利用可能性

ローカル動作、削除済みデータの扱い、通信の暗号化、アカウントの管理に関しては実際にサービスや Web アプリを使用して調査した。

クラウドの分離に関してはサービスや Web アプリを提供する各社の公式情報を用いて調査を行った。

#### 6.2.5. 総合評価

今までの調査結果の集計をもって総合評価とした。

評価の基準は別紙表 28 を参照のこと。

### 6.3. 調査結果

2024年1月時点の調査では Azure + GPT4 が OpenAI 社の GPT による精度と機密情報取り扱い時のセキュリティの点で優位であり、スプレッドシート、PDF など多様なファイル形式に対応し、レイアウトの整形が可能で、閉鎖環境に対応した Azure + GPT4 を適用可能性評価の対象及びプロトタイプ開発環境として選定した。

表 5：技術調査結果一覧

評価項目	Tableau prep	Azure + GPT4	ChatGPT	Bedrock + Claude 2.1	Gemini Pro	LLaMA
多様なファイル形式	△	○	○			
レイアウトの整形	○	○	○			
地方公共団体での利用可能性		○		○	△	△

2024年1月調査

調査内容の詳細は別紙表 28 を参照のこと。

#### 6.3.1. Tableau prep

##### 6.3.1.1. 多様なファイル形式

スプレッドシートは問題なく読み込めるが、PDF の表は崩れてしまうケースが多かった。Zip はそのまま読むことはできなかった。文字コードに関して JIS 以外は自動的に対応していた。

表 6：多様なファイル形式調査結果 (Tableau prep)

評価内容／調査結果		評価
評価内容	xls、xlsx を読み込めるか	○
調査結果	読み込めた。	
評価内容	PDF を読み込めるか	△
調査結果	<ul style="list-style-type: none"> <li>最新バージョン(2023.3.2)では、日本語のファイル名が読めなくなっている。</li> <li>テーブルの読み込みが不安定であり、テーブルごとにファイルを複製するなど、特殊なテーブル形式以外のテキストは非対応。Acrobat Pro を使用してスプレッドシートに変換すると精度が高まった。</li> <li>読み込めるケースもあるが、日本語に対応していないなどの問題もあった。</li> </ul>	
評価内容	ZIP 化された CSV を読み込めるか	×
調査結果	事前に ZIP の展開が必要なので、そのままでは読めなかった。	
評価内容	Unicode 以外の JIS、SJIS、EUC を読み込めるか	△
調査結果	SJIS：自動で読み込めた。 EUC：自動で読み込めた。 JIS：読み込み時にエンコードを指定することで読み込めた。	

##### 6.3.1.2. レイアウトの整形

スプレッドシートはうまく読み込めたが、PDF の表は崩れてしまうケースが多かった。

表 7：レイアウトの整形調査結果 (Tableau prep)

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	△
調査結果	問題なく読み込めたが、読み込んだ後ページ単位になった	

評価内容	同一ページに複数の表があった場合	○
調査結果	問題なく読み込めた。表の結合も可能だった。	
評価内容	同一ページにグラフが混載された場合	△
調査結果	スプレッドシート：グラフは無視して表データのみ取得した。 PDF：表が崩れ、正しく読むことができなかった。	
評価内容	項目名がセル結合された場合	○
調査結果	問題なく読み込めた。	
評価内容	データがセル結合された場合	△
調査結果	スプレッドシート：複数列の結合は、2列目以降が null 値。複数行の結合は、1行目のデータが2行目以降にコピーされた。 PDF：表が崩れ、正しく読むことができなかった。	
評価内容	横書きと縦組みの表が混載された場合	△
調査結果	スプレッドシート：問題なく読み込めた。 PDF：表が崩れ、正しく読むことができなかった。	
評価内容	外字が使われた場合	△
調査結果	入力時に正しく文字コードを指定することで UTF-8 に変換できた。	

### 6.3.1.3. 地方公共団体での利用可能性

ローカル PC で実行する形式だが、インターネット接続が必要。セキュリティは担保されているが、クラウドサーバーは日本にはない。

表 8：地方公共団体での利用可能性調査結果 (Tableau prep)

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	△
調査結果	ローカルでは不可能だった。 起動時にライセンス認証のため、インターネット接続が必要。	
評価内容	キャッシュなど中間ファイルは残るか	×
調査結果	ログファイルと最近アクセスしたデータが指定のフォルダに格納されことを確認した。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	○
調査結果	意図して公開しない限り、組織の範囲外からは閲覧不可能だった。	
評価内容	アカウントは MFA など最新技術で保護されているか	△
調査結果	多要素認証はサポートされていた。ただし、管理者側の設定で回避することも可能だった。	
評価内容	クラウドサーバーは日本にあるか	×
調査結果	日本にない。	

### 6.3.1.4. 全体のまとめ

スプレッドシートは問題なく読み込めても、PDF の表は崩れてしまうケースが多かった。Adobe 社の Acrobat Pro を使用し、スプレッドシートに変換して読み込ませることで精度の向上が見られた。セル結合は項目名には対応できるがデータ側には対応できなかった。PDF ではもともと表自体が読み込めない。

最新版(2023.3.2)では日本語名のファイルが開けなくなっていた。

ローカル PC にインストールできるが、起動時のライセンス認証のためインターネット接続が必要となった。サーバーは日本にはなく、中間ファイルがサーバーに残ってしまいセキュリティ上の懸念があった。

## 6.3.2. Azure + GPT4

### 6.3.2.1. 多様なファイル形式

Azure + GPT4 はスプレッドシートを問題なく読み込むことができた。Unicode 以外のエンコーディングが使用されている場合には、nkf (Network Kanji Filter) を自動的に利用して適切に処理されていた。PDF に関しては、テキストベースの内容は正常に読み込むことが可能であった。しかし、ページをまたがる表など複雑なレイアウトを含む場合は、分割された状態で表示された。ZIP された CSV テキストファイルも問題なく読み込んだ。JIS、SJIS、EUC の Unicode 以外の文字コードによるテキストファイルも、正確に読み込んだ。

表 9：多様なファイル形式調査結果 (Azure + GPT4)

評価内容／調査結果		評価
評価内容	xls、xlsx を読み込めるか	○
調査結果	読み込んだ。	
評価内容	PDF を読み込めるか	△
調査結果	複雑な表形式の場合は問題が発生した。	
評価内容	ZIP 化された CSV を読み込めるか	○
調査結果	読み込んだ。	
評価内容	Unicode 以外の JIS、SJIS、EUC を読み込めるか	○
調査結果	SJIS：自動で読み込んだ。 EUC：自動で読み込んだ。 JIS：自動で読み込んだ。	

### 6.3.2.2. レイアウトの整形

ページ読み飛ばしについては、自動で読み飛ばすことはできなかったが、ページ番号を指定すれば読み飛ばすこと確認できた。複数の表については、それぞれを認識し結合できた。グラフが混載された場合も問題なく読み込んだ。項目名がセル結合された場合は読み込むことができたが、項目名やデータがセル結合された状態で認識されていなかった。縦組みについては正しく読み込むことができていた。

表 10：レイアウトの整形調査結果 (Azure + GPT4)

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	△
調査結果	スプレッドシート：シート名を指定して読み込んだ。 PDF：自動で読み込まず、ページ数を指定しても表を読み込めなかった。	
評価内容	同一ページに複数の表があった場合	△
調査結果	1 ページに収まった表は読み込んだが、複数ページにまたがった表は結合できなかった。指示を変更しても不可能だった。	
評価内容	同一ページにグラフが混載された場合	○
調査結果	問題なく読み込んだ。	
評価内容	項目名がセル結合された場合	△
調査結果	スプレッドシートとして出力したがセル結合された状態にはならなかった。行ずれなどは起こしておらず、手作業でセル結合すればよい状態になった。	
評価内容	データがセル結合された場合	△
調査結果	スプレッドシート：セル結合された状態ではないがカラム・行ずれは発生しなかった。 PDF：データが欠損した。	
評価内容	横書きと縦組みの表が混載された場合	△



評価内容／調査結果		評価
調査結果	スプレッドシート：セル結合された状態ではないがカラム・行ずれは発生しなかった。 PDF：データが欠損した。	
評価内容	外字が使われた場合	○
調査結果	UTF-8 に正常に変換された。	

### 6.3.2.3. 地方公共団体での利用可能性

Azure + GPT4 は Web サービスでの利用を前提としているため、ローカルで動作させることは不可能である。中間ファイルは残らず、ブラウザから利用するため HTTPS 通信によって暗号化されている。また、クラウド上のデータは意図して共同作業グループを作らない限り、契約者以外からは閲覧できない。マイクロソフトのアカウントが必要なため MFA (Multi-Factor Authentication: 多要素認証) を設定することが可能である。クラウドサーバーは東日本にある。

表 11：地方公共団体での利用可能性調査結果 (Azure + GPT4)

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	×
調査結果	ローカルでは不可能だった。	
評価内容	キャッシュなど中間ファイルは残るか	○
調査結果	残らなかった。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	○
調査結果	意図して共同作業グループを作らない限り、他からは閲覧できない。	
評価内容	アカウントは MFA など最新技術で保護されているか	○
調査結果	Google 認証、マイクロソフトアカウント認証によって保護されていた。ただし Email でアカウントを作成した場合は MFA が非対応だった。	
評価内容	クラウドサーバーは日本にあるか	×
調査結果	日本にある。	

### 6.3.2.4. 全体のまとめ

Azure + GPT4 は ChatGPT と同一の生成 AI モデルを用いているが、以下の条件により ChatGPT とは挙動が変わる。

- 1) 学習データの時期
- 2) 外部 API アクセスの許可。
- 3) プライバシーフィルターの有無
- 4) 各種パラメーターの設定

スプレッドシートや PDF は ChatGPT と同じくそのまま読み込むことができる。知識量は ChatGPT よりも Azure + GPT4 の学習時期が古いいため少ない。データ処理速度は Azure が若干遅い。データ補完や Python の実行エラーの自動修正の繰り返し数は Azure が優勢である。外部 API アクセスが制限されていないため Geocoder などによるデータ補完は Azure ならば完全に動作する。トークン

費は ChatGPT とまったく同じ。ChatGPT で見られるデータ容量が大きくなると処理を中断する可能性が Azure では低下しより大きなデータでも繰り返し処理を試みる。

セキュリティに関して Azure は閉鎖環境でありアクセス許可をしたユーザー以外とはデータ共有されず安全である。

ファイル読み込みの対応など ChatGPT 相当の機能に加え、データ補完も可能であることから適用可能性評価の対象と考えた。

### 6.3.3. ChatGPT Plus

#### 6.3.3.1. 多様なファイル形式

ChatGPT はスプレッドシートを問題なく読み込むことができた。Unicode 以外のエンコーディングが使用されている場合も読み込むことができた。PDF に関しては、テキストベースの内容は正常に読み込むことが可能であった。しかし、ページをまたがる表など複雑なレイアウトを含む場合は、分割された状態で表示された。ZIP 化された CSV テキストファイルも問題なく読み込んだ。JIS、SJIS、EUC の Unicode 以外の文字コードによるテキストファイルも、正確に読み込んだ。

表 12：多様なファイル形式調査結果（ChatGPT Plus）

評価内容／調査結果		評価
評価内容	xls、xlsx を読み込めるか	○
調査結果	読み込んだ。	
評価内容	PDF を読み込めるか	△
調査結果	複雑な表は整形されなかった。	
評価内容	ZIP 化された CSV を読み込めるか	○
調査結果	読み込んだ。	
評価内容	Unicode 以外の JIS、SJIS、EUC を読み込めるか	○
調査結果	SJIS：読み込んだ。	
	EUC：読み込んだ。	
	JIS：読み込んだ。	

#### 6.3.3.2. レイアウトの整形

ページ読み飛ばしについては、スプレッドシートだとシート名を指定して確認できた。PDF だと読み込むことができなかった。複数の表については、読み込むことはできたが結合はできなかった。グラフが混載された場合も問題なく読み込んだ。項目名がセル結合された場合は読み込むことができた。縦組みについては正しく読み込むことができていた。

表 13：レイアウトの整形調査結果（ChatGPT Plus）

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	△
調査結果	スプレッドシート：シート名を指定して対応した。 PDF：読み込めなかった。	
評価内容	同一ページに複数の表があった場合	△

評価内容／調査結果		評価
調査結果	ページ内の表は読み込めたが、複数ページにまたがった表は結合できなかった。指示を変更しても結合不可だった。	
評価内容	同一ページにグラフが混載された場合	○
調査結果	読み込めた。	
評価内容	項目名がセル結合された場合	△
調査結果	スプレッドシート化して出力したがセル結合された状態にはならなかった。行ずれなどは発生せず、手作業で対応可能な状態だった。	
評価内容	データがセル結合された場合	△
調査結果	スプレッドシート：セル結合された状態ではないもののカラム・行ずれを起こさずに読み込めた。 PDF：データが欠損した。	
評価内容	横書きと縦組みの表が混載された場合	△
調査結果	スプレッドシート：セル結合された状態ではないもののカラム・行ずれを起こさずに読み込めた。 PDF：データが欠損した。	
評価内容	外字が使われた場合	○
調査結果	UTF-8 に正常に変換された。	

#### 6.3.3.3. 地方公共団体での利用可能性

ChatGPT は Web サービスでの利用を前提としているため、ローカルで動作させることは不可能である。中間ファイルは残らず、ブラウザから利用するため HTTPS 通信によって暗号化されている。また、クラウド上のデータは意図して共同作業グループを作らない限り、契約者以外からは閲覧できない。OpenAI または Google, Microsoft, Apple アカウントでログインすることができる。それぞれ MFA (Multi-Factor Authentication: 多要素認証) を設定することが可能である。クラウドサーバーは日本にない。

表 14：地方公共団体での利用可能性調査結果 (ChatGPT Plus)

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	×
調査結果	元々が Web サービスなので、ローカルでは不可能だった。	
評価内容	キャッシュなど中間ファイルは残るか	○
調査結果	残らなかった。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	○
調査結果	意図して共同作業グループを作らない限り、他からは見られない。	
評価内容	アカウントは MFA など最新技術で保護されているか	○
調査結果	Google 認証、またはマイクロソフトアカウント認証で保護されている。ただし Email でアカウント作成した場合は MFA が非対応だった。	
評価内容	クラウドサーバーは日本にあるか	×
調査結果	日本にない。	

#### 6.3.3.4. 全体のまとめ

基本的に Azure + ChatGPT4 と同じ生成 AI モデルだが、

- 1) 学習データの時期
- 2) 外部 API アクセスの許可
- 3) プライバシーフィルターの有無
- 4) 各種パラメーターの設定

によって挙動が変わる。

知識量は ChatGPT Plus の方が多く、処理速度も速いが、データ補完や Python の実行エラーの自動修正の繰り返し数は Azure よりも低下する。外部 API アクセスが制限されているため Geocoder などによるデータ補完には対応できない。トークン費は Azure とまったく同じだった。

データ処理速度は Azure より若干早い、データ容量が大きくなると処理を中断する可能性が Azure よりも高まる。

セキュリティに関してはアップロードしたデータ・プロンプトからの再学習をユーザー設定で禁止できるが、公開サーバーにファイル登録している点で Azure 閉鎖環境よりもセキュリティは低下する。

手軽に使えるが、機密情報取り扱い上の懸念とデータ補完の非対応から適用可能性評価の対象外とした。

#### 6.3.4. Bedrock + Claude 2.1

##### 6.3.4.1. 多様なファイル形式

Bedrock ではファイルのコンバートができなかった。前もってファイルをコンバートし、テキスト形式化することで読ませることができた。また、Bedrock の Knowledge base 機能では、表を抽出して出力することはできなかった。

この評価項目では Bedrock 単体でのファイルの読み込みを検証している。

表 15：多様なファイル形式調査結果 (Bedrock)

評価内容／調査結果		評価
評価内容	xls、xlsx を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	PDF を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	ZIP 化された CSV を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	Unicode 以外の JIS、SJIS、EUC を読み込めるか	×
調査結果	読み込めなかった。	

※ 調査では Knowledge base を使ってファイルをコンバートして読み込ませた。

##### 6.3.4.2. レイアウトの整形

前項のファイルフォーマットで検証した通り、Bedrock 単体ではファイルのコンバートができず、表として認識することができなかった。

表 16：レイアウトの整形調査結果（Bedrock）

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	同一ページに複数の表があった場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	同一ページにグラフが混載された場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	項目名がセル結合された場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	データがセル結合された場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	横書きと縦組みの表が混載された場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	
評価内容	外字が使われた場合	×
調査結果	Bedrock だけではファイルを読み込めなかった。	

#### 6.3.4.3. 地方公共団体での利用可能性

Bedrock はクラウドサービスであるので、ローカルでは実行できないもののセキュリティはきちんとしている。現時点では海外のクラウドで運用されている。

表 17：地方公共団体での利用可能性調査結果（Bedrock）

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	×
調査結果	Bedrock 自体がクラウド上のサービスであるため、ローカルでは不可能だった。	
評価内容	キャッシュなど中間ファイルは残るか	○
調査結果	残らなかった。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	○
調査結果	AWS の IAM で、権限設定が可能だった。	
評価内容	アカウントは MFA など最新技術で保護されているか	○
調査結果	保護されている。	
評価内容	クラウドサーバーは日本にあるか	×
調査結果	調査時点では北米のみ対応していた。	

#### 6.3.4.4. 全体のまとめ

Bedrock + Claude 2.1 は生成した Python を実行する機能（インタープリタ）を持たないため、データ整形は生成 AI が直接行うことになる。そのためハルシネーションという間違った回答の抑制が困難な可能性が懸念された。

インタープリタを持たないため、スプレッドシートや PDF を直接読むことができず、Knowledge base という RAG ツールでファイルを認識させるか、事前にファイルを CSV に変換してから生成 AI

に読み込ませなければならなかった。そのため、Claude 2.1 単体でのファイルフォーマットとレイアウトの調査に関して不可能だった。

セキュリティに関しては、生成 AI である Claude 2.1 は東京リージョンで使えたが、ファイルを渡すための Knowledge base が日本に存在しないため、北米リージョンを利用した。そのため Knowledge base の UI は日本語化されていない。

### 6.3.5. Gemini Pro

#### 6.3.5.1. 多様なファイル形式

Google 社の Gemini Pro は直接ファイルを添付できないので、プロンプトに埋め込む形でデータを渡して処理を行った。スプレッドシートも PDF もファイルの内容をテキスト化したのだが、PDF に関しては、全ページを読み込ませるとトークン数が上限を超えてしまうため、最初の 10 ページのみを処理させた。

ZIP 圧縮された CSV については正しく内容を理解することができた。Unicode 以外の文字コードを含むファイルでは、デフォルトの設定が UTF-8 なのでエラーが発生したが、エンコーディングを明示的に指定することで、読み込むことができた。Gemini Pro Vision では OCR 読み取りが可能であるため、PDF を JPEG に変換して添付することで文字認識をさせることができた。表形式も認識できたが、OCR であるためデータの数字を読み間違えるなどの問題が見られた。

表 18：多様なファイル形式調査結果 (Gemini Pro)

評価内容／調査結果		評価
評価内容	xls、xlsx を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	PDF を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	ZIP 化された CSV を読み込めるか	×
調査結果	読み込めなかった。	
評価内容	Unicode 以外の JIS、SJIS、EUC を読み込めるか	△
調査結果	エンコーディングを指定して読み込ませた。	

※ 調査では Python を使ってデータをプロンプトに埋め込んで対応した。

#### 6.3.5.2. レイアウトの整形

先頭の数ページを読み飛ばしてからのデータの読み取りと、同一ページ内に複数の表があるケースでは、正しく処理されなかった。原因は、PDF の構成が変換の途中で破損したためである。グラフが混載されたケースではデータ抽出を行った時点でグラフは抽出されなかった。

項目名がセル結合されたケースでは、おおむね正しいが一部間違った内容を返してきた。また、セル結合されていないセルを結合されていると誤答した例もあった。列の結合は検出できていたが、行の結合は検出することができなかった。

縦組みのデータについては認識できなかった。

外字が使われている場合は Unicode 以外の文字コードを含むファイル同様、エンコーディングを「cp932」と明示的に指定しなければ読み込めなかった。

表 19：レイアウトの整形調査結果 (Gemini Pro)

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	×
調査結果	誤答した。	
評価内容	同一ページに複数の表があった場合	×
調査結果	誤答した。	
評価内容	同一ページにグラフが混載された場合	×
調査結果	グラフは抽出しなかった。	
評価内容	項目名がセル結合された場合	×
調査結果	セル結合が解除され、認識されなかった。	
評価内容	データがセル結合された場合	×
調査結果	セル結合が解除され、認識されなかった。	
評価内容	横書きと縦組みの表が混載された場合	×
調査結果	縦組みが解除され、認識されなかった。	
評価内容	外字が使われた場合	×
調査結果	エンコーディングを指定して読み込ませた。	

### 6.3.5.3. 地方公共団体での利用可能性

Gemini Pro は Google Cloud の Vertex AI Studio という Web UI、または API で利用することができる。そのため、ローカルで動作させることは不可能である。中間ファイルについては「Gemini アプリ アクティビティ」をオフに設定すれば残さないようにできるが、他サービスの改善のため利用され、最長 72 時間は強制保存される。クラウド上のデータは意図的に共同作業グループを作らない限り、契約者以外からは閲覧できない。Google のアカウントを使用するため、MFA を設定することができる。また、位置情報や他のサービス改善のために入力したプロンプトはオフ設定であっても活用される。

表 20：地方公共団体での利用可能性調査結果 (Gemini Pro)

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	×
調査結果	API を介して利用するため、ローカルでは不可能だった。	
評価内容	キャッシュなど中間ファイルは残るか	△
調査結果	設定可能だが、他サービスの改善のため利用され、最長 72 時間は強制保存される。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	△
調査結果	意図して共同作業グループを作らない限り、外部からは閲覧不可能。	
評価内容	アカウントは MFA など最新技術で保護されているか	○
調査結果	保護されている。	
評価内容	クラウドサーバーは日本にあるか	○
調査結果	東京リージョンで利用可能。	

プロンプトやファイルといったデータは、Google による利活用が明確に記述されており、機密情報保護に懸念が残るため適用可能性評価の対象外とした (図 8)。

図 8 : Gemini アプリのプライバシーハブ

Google アカウントに会話を保存せずに Gemini アプリを使用したい場合は、[Gemini アプリ アクティビティをオフ](#)にすることができます。[myactivity.google.com/product/gemini](https://myactivity.google.com/product/gemini) では、メッセージを確認したり、[Gemini アプリ アクティビティ] から会話を削除したりできます。

人間のレビュアーが確認した、または注釈を付けた会話（および言語、デバイスの種類、位置情報、フィードバックなどの関連データ）は別途保存され、Google アカウントには関連付けられないため、Gemini アプリ アクティビティを削除しても消えることはありません。こうした会話は、最長で 3 年間保存されます。

[Gemini アプリ アクティビティ] がオフになっている場合でも、会話は最長で 72 時間アカウントに保存されます。この期間は、Google がサービスを提供し、フィードバックを処理するために設けられています。このアクティビティはユーザーの [Gemini アプリ アクティビティ] には表示されません。[詳細](#)

この設定をオフにした場合や Gemini アプリ アクティビティを削除した場合、[ウェブとアプリのアクティビティ](#)や[ロケーション履歴](#)などの設定により、他の Google サービスの使用の一環として、位置情報などのデータが引き続き保存されることがあります。また、Gemini アプリを他の Google サービスと統合して使用する場合、データはサービスのポリシーおよび Google の[プライバシー ポリシー](#) に準拠してサービスを提供、改善するために使用されます。サードパーティ サービスとのやり取りに Gemini アプリを使用する場合は、ユーザーデータは各サービスのプライバシー ポリシーに従って処理されます。

閲覧日: 2024 年 2 月 8 日

#### 6.3.5.5. 全体のまとめ

Gemini Pro は生成した Python を実行する機能（インタープリタ）を持たないため、データ整形は生成 AI が直接行うことになる。そのためハルシネーションという間違った回答を抑制することが困難な可能性が懸念された。

インタープリタを持たないため、スプレッドシートや PDF を直接読むことができず、CSV ファイルを読み込みプロンプトに埋め込むことで生成 AI に読み込ませた。そのため、エンコーディングを指定しないと読み取ることができず、グラフなどは抽出されなかった。

セキュリティに関しては、中間ファイルについて他サービスの改善のため利用され、最長 72 時間は強制保存される。

#### 6.3.6. LLaMA

##### 6.3.6.1. 多様なファイル形式

LLaMA2 はオープンソースであり、研究用途だけでなく、商用利用も可能であり無料で公開されている。

調査においては、機械学習モデルや AI 技術を試行できるプラットフォーム、Replicate 上の API を利用した。

PDF は、全ページを LLaMA に読み込ませるとトークン数が上限を超えてしまうため、最初の 10 ページのみを読み込ませたが、スプレッドシートも PDF も数字の羅列になってしまった。データが数字の文字列であるため、LLaMA がこれを適切な表形式として認識できていない可能性がある。ZIP 化された CSV の読み込みと Unicode 以外のエンコーディングに関しても、エンコード



を指定して読み込ませても誤答をした。

表 21：多様なファイル形式調査結果（LLaMA）

評価内容／調査結果		評価
評価内容	xls、xlsxを読み込めるか	×
調査結果	読み込めなかった。	
評価内容	PDFを読み込めるか	×
調査結果	読み込めなかった。	
評価内容	ZIP化されたCSVを読み込めるか	×
調査結果	読み込めなかった。	
評価内容	Unicode以外のJIS、SJIS、EUCを読み込めるか	×
調査結果	読み込めなかった。	

### 6.3.6.2. レイアウトの整形

LLaMA は直接ファイルを添付できないので、前節同様、文字列に変換したデータをプロンプトに埋め込み、処理をさせた。PDF に関しては、全ページを LLaMA に読み込ませるとトークン数が上限を超えてしまうので最初の 10 ページのみを読み込ませた。

どのケースにおいても数字の羅列になってしまっていた。

表 22：レイアウトの整形調査結果（LLaMA）

評価内容／調査結果		評価
評価内容	先頭の数ページを読み飛ばしてからのデータ読み取り	×
調査結果	誤答した。	
評価内容	同一ページに複数の表があった場合	×
調査結果	誤答した。	
評価内容	同一ページにグラフが混載された場合	×
調査結果	誤答した。	
評価内容	項目名がセル結合された場合	×
調査結果	誤答した。	
評価内容	データがセル結合された場合	×
調査結果	誤答した。	
評価内容	横書きと縦組みの表が混載された場合	×
調査結果	誤答した。	
評価内容	外字が使われた場合	×
調査結果	誤答した。	

### 6.3.6.3. 地方公共団体での利用可能性

LLaMA はオープンソースであり、ローカルで動作させることが可能である。また、外部サービスとして公開されている API もある。中間ファイルに関しては、LangChain を使用した場合、残る可能性がある。クラウドとの通信は暗号化されており、クラウド上のデータは private または public に設定することができる。Replicate のログインには GitHub アカウントが必要であり、GitHub には MFA の設定が可能である。

表 23：地方公共団体での利用可能性調査結果（LLaMA）

評価内容／調査結果		評価
評価内容	ローカル PC だけで動作可能か	○
調査結果	可能だった。	
評価内容	キャッシュなど中間ファイルは残るか	△
調査結果	LangChain を使用した場合、残る可能性がある。	
評価内容	クラウドとの通信は暗号化されているか	○
調査結果	https を使用している。	
評価内容	クラウド上のデータは契約者以外から見られないか	○
調査結果	private または public に設定できる。	
評価内容	アカウントは MFA など最新技術で保護されているか	○
調査結果	Replicate は GitHub のアカウントによるログインが可能だった。	
評価内容	クラウドサーバーは日本にあるか	×
調査結果	不明	

#### 6.3.6.4. 全体のまとめ

LLaMA は Gemini Pro 同様、生成した Python を実行する機能（インタープリタ）を持たないため、データ整形は生成 AI が直接行うことになる。

インタープリタを持たないため、スプレッドシートや PDF を直接読むことができず、CSV ファイルを読み込みプロンプトに埋め込むことで生成 AI に読み込ませた。スプレッドシートも PDF も数字の羅列になってしまった。データが数字の文字列であるため、LLaMA がこれを適切な表形式として認識できていない可能性がある。

LLaMA はオープンソースなので、ローカルで動作させることが可能であり無料で利用できる。また、外部サービスとして公開されている API もあり、別途料金がかかるものもある。

#### 6.3.7. 画像認識によるデータ整形

令和 6 年 1 月時点では閉鎖環境の生成 AI でテキストの画像認識機能が提供されている地域は限定されているため、データを提供いただいた地方公共団体の許可を得て画像形式の PDF をオープン環境の生成 AI でデータ整形を試みた。調査に用いたデータは図 9 に示す広報誌の PDF の中からデジタル化する領域を手書きの赤枠で囲んだものを使用した。

図 9：画像認識調査用 PDF

六角堂広場、展示室					
開催日	時間	会場	イベント名	料金など	お問合せ
2月	3(金) 4(土) 5(日)	10:00~ 18:00	ヨーロッパ輸入食器専門店主催 特価セール&アート展	無料	ヨーロッパ輸入食器専門店 sohbzアパロス福岡店 ☎092-713-0871
	4(土)	10:30~ 16:00	チョコっと♥バレンタイン	無料	美ハイマート久留米 ☎/☎0942-38-5677
	18(土) 19(日)	10:00~ 15:00	宇宙Hack! in Fukuoka	無料	(一社)航空宇宙博覧会夢街 ☎080-9101-5984 so:info@aspia.info
	25(土)	10:00~ 15:00	第7回キラリ☆マルシェ	無料	(一社)アカルカ福祉協会 ☎090-8625-8833
3月	26(日)	10:00	久留米シティプラザ ジュニアダンスステージ in 六角堂広場	全日 無料	久留米シティプラザ ☎0942-36-3000
会議室、スタジオ、和室					
開催日	時間	会場	イベント名	料金など	お問合せ
2月	1(水)	18:13:00	笑いの終活お金講座	有料 随席券	FP事務所藤村 藤村 ☎0942-38-7061 so:toiwase@fprashinban.com
	2(木)	25/14:00			

### 6.3.7.1. Claude 2.1

異なる PDF ファイルを 4 つ (図 10) 試みたが、テキスト情報を読み取れるものはなかった。4 ファイルとも広報誌の PDF であるためレイアウトとファイルフォーマットは同一であるが、生成 AI の返答内容は毎回異なった。

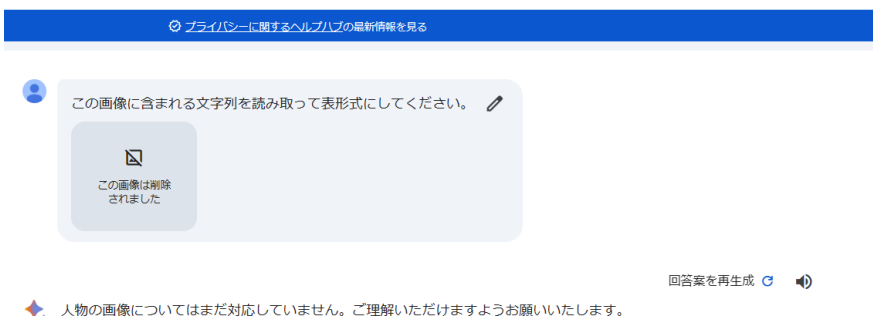
図 10 : Claude 2.1 の画像型 PDF 処理結果



### 6.3.7.2. Google Bard

令和 6 年 1 月時点では Google Bard は PDF を直接読み込めない (図 11)。プロンプトを通して PDF を読み取る方法を Google Bard に確認したところ、何らかのツールで PDF をテキストに変換してからアップロードされるように指示された。そこで、PDF をブラウザで表示させスクリーンショットを取得して画像ファイルを作成し、その画像ファイルを Google Bard に添付したところ、人物が含まれていたためプライバシー対応のために処理が停止されてしまった。

図 11 : Google Bard のファイル添付



### 6.3.7.3. ChatGPT

ChatGPT3.5 ではファイルアップロード機能が存在せず調査対象外とした。ChatGPT4 はファイルアップロードに対応しているため、こちらを調査した。

ChatGPT4 に PDF を読み込ませたところ、表 24 のような対話となった。JPEG を含んだ PDF であることは識別されており、画像認識でカレンダーかイベント情報であることが推測された。その後、何度か自動的にエラーを回復しながら読み取りを試みたが、時間がかかってタイムアウトしてしまったようで処理結果は得られなかった。

表 24 : ChatGPT4 の画像認識チャット記録

The document you uploaded appears to be an image format (JPEG) within a PDF, showing a calendar or event information. Since it's in an image format, I can't directly read or extract text from it. To assist you further, could you please provide details on the specific sections you need to be converted into a table format? This will help me understand which parts of the content you're interested in, and I can guide you on how to proceed.
赤枠で囲った部分は、6月24日から始まるページの上半分全体を占めているとのことですが、残念ながら PDF 内の画像から直接テキストを読み取ることはできません。しかし、この PDF を画像として扱い、そこからテキストを抽出することは可能です。 このプロセスには、画像からテキストを抽出する OCR（光学文字認識）技術の使用が含まれます。まず、私は PDF から該当する画像を抽出し、その後 OCR プロセスを通じてテキストを読み取ります。その結果をもとに、必要な情報を表形式に変換します。これを行ってよろしいでしょうか？
Error analyzing 私のコードで小さなエラーがありました。io モジュールを明示的にインポートするのを忘れてしまいました。これを修正して、もう一度 OCR プロセスを実行します。少々お待ちください。
Error analyzing OCR プロセス中に問題が発生しました。現在の環境では、日本語の OCR データファイルが利用できないようです。この問題を解決するためには、適切な日本語のテッサラクトデータファイルが必要ですが、私の現在の環境ではそれが利用できません。 代わりに、画像内のテキストを手動で読み取ることが可能ですが、これは時間がかかり、精度も完全ではありません。また、画像の品質やテキストの量によっては、正確な読み取りが難しい場合があります。この方法で進めるか、別の方法を検討しますか？
了解しました。赤枠で囲まれた部分のテキストを手動で読み取り、表形式に変換する作業を行います。この作業は少し時間がかかる可能性がありますので、しばらくお待ちください。 現在、PDF ファイルを手動で読み取り、テキストを表形式に変換する作業を行っています。ファイルが大きく、詳細なテキストが含まれているため、この作業には時間がかかります。完了次第、結果をお知らせしますので、しばらくお待ちください。

### 6.3.7.4. 全体のまとめ

画像型 PDF で赤枠を囲んだ領域を読み取らせる調査をしたところ、Claude 2.1 はテキスト情報を読み取れるものはなかった。また、生成 AI の返答内容は毎回異なった。Google Bard は PDF を直接読み込めないため、画像ファイルにしたのち Google Bard に添付したところプライバシー対応のために処理が停止されてしまいテキストを読み取れなかった。ChatGPT4 は自動的にエラーを回復しながら読み取りを試みたが、時間がかかってタイムアウトした。

よって、これらの生成 AI では赤枠を囲んだ領域からのテキスト抽出の処理結果は得られなかった。

#### 6.4. 技術調査による考察

生成 AI の調査においてスプレッドシートと PDF の読み込みに大きな差が出た。調査時点では生成 AI はバイナリ形式を直接読み込むことができなかったため、インタープリタ機能が搭載されているか否かの差異が要因である。詳細は別紙図 26 を参照。

プロンプト上でファイルのアップロードが可能であり、PDF ファイルを扱うときに事前の処理が必要なく、多様なファイル形式の読み込みに対応し、レイアウトの整形が可能で、閉鎖環境にも対応している Azure + GPT4 が、今回の実証で地方公共団体に利用してもらうのに最適と判断し、適用可能性調査の対象及びプロトタイプ開発環境として選定した。

## 7. 適用可能性評価

一般に提供されている ChatGPT などの生成 AI のツールはオープンなクラウド環境であり、機密情報への対応が十分になされていない。また、API 経由で利用したとしてもオープンなクラウド環境に変換元データをアップロードする事となり機密情報対応が十分とは言えない。

そのため、クラウド上に独自の閉鎖環境を構築し、その中に各社から提供されている AI モデルを展開することによって、閉鎖環境で動作する生成 AI の試験環境を作成した。各クラウドが提供する閉鎖環境向けの動作確認ツールは Playground と呼ばれるが、そこはテキスト形式のチャットしか対応しておらず、変換したいファイルの添付ができなかった。そこで、プロトタイプとして開発したシステムを適用可能性評価に転用した。

### 7.1. 調査内容

技術調査時に使用した地方公共団体から提供されたデータを、あらためて自治体標準 ODS に変換できるか調査を行ったほか、同時に、実行計画時に想定されていなかった現象を把握するため、地方公共団体ごとに 10 ケースずつデータ整形も行った（表 25）。

地方公共団体から提供されたデータの内容が自治体標準 ODS に適合しないものがあり 10 ケースに届かなかった地方公共団体もある。

この整形・変換調査を通して、「3.3. 適用可能性評価」で規定した評価を行った。

表 25：地方公共団体提供による各種データの整形結果

ID	自治体標準オープンデータセット	小規模地方公共団体	中規模地方公共団体	都道府県
1	公共施設一覧	PDF 項目名：○ データ補完：40%		公共施設一覧は元データが自治体標準 ODS 準拠
3	指定緊急避難場所一覧	スプレッドシート 項目名：○ データ補完：100%	スプレッドシート 項目名：○ データ補完：100%	
4	地域・年齢別人口	PDF 項目名：○ データ補完：該当せず		
8	AED 設置箇所一覧	PDF 項目名：○ データ補完：0%	PDF 項目名：○ データ補完：0%	
9	介護サービス事業所一覧		スプレッドシート 項目名：○ データ補完：0%	
10	医療機関一覧			PDF 項目名：○ データ補完：93%
10'	医療機関一覧 (助産所)		スプレッドシート 項目名：○ データ補完：100%	
10''	医療機関一覧 (整体)		スプレッドシート 項目名：× データ補完：na	
16	学校給食献立情報 (小学校)	スプレッドシート 項目名：× データ補完：na		
16'	学校給食献立情報 (中学校)	スプレッドシート 項目名：× データ補完：na		
DM-7	赤ちゃんの駅 (データモデル型)			

## 7.2. 実施ステップ

適用可能性評価には Azure + GPT4 を使用し、データ変換の調査を行った。

### 7.2.1. ファイル添付方法

表形式のスプレッドシートや PDF を処理させるために、以下の方法でファイルを添付した。

Azure Storage サービスを作成し、そこに処理をさせるファイルをアップロードする。該当するファイルの URL をプロンプトに渡すことでファイル処理を可能にした。なお、複数ファイルの指定も可能にした。

## 7.3. 評価結果

Azure + GPT4 を用いて、以下の評価項目で機能評価を行い、対応できることを確認した。

表 26: 評価結果

	評価項目	評価内容	評価結果
ファイル結合	複数ファイル	複数のファイルを結合できるか	○
	主キー参照	主キーをもとに同一行に補完できるか	○
	複数キー参照	複数キーをもとに同一行に補完できるか	○
	項目名の自動振り分け	住所/アドレスなど揺らぎのある項目名を結合できるか 違う項目名を統合できるか	○
テキスト処理	テキスト分割	東京都千代田区などを都と区に分離できるか	○
	テキスト結合	東京都、千代田区を東京都千代田区に結合できるか	○
	表記ゆれ検出	東京都、Tokyo などの表記揺れを検出できるか	○
	半角・全角	半角・全角の表記揺れを検出できるか	○
	表記ゆれ修正	検出された表記揺れを修正できるか	○
	読み仮名	カナ・英字の読み仮名を作れるか	○
データ補完	不足項目検出	項目名で不足分を割り出せるか	○
	全国地方公共団体コード	補完データ取得可能か	○
	町字 ID	補完データ取得可能か	○
	緯度経度	団体名・住所から緯度経度を割り出せるか	○
	郵便番号	住所から郵便番号を探せるか	○
調査から外した項目	POI コード	補完データ取得可能か	○
	法人番号	体名・住所から法人番号を割りだせるか	○
	URL	URL リンク先が適切か確認できるか	○

### 7.3.1. 有用なプロンプト

調査を通してプロンプトによるデータ変換を成功させやすい方法と、成功確率の高いプロンプトのあり方が見えてきた。以下にそれを記す。

#### [成功するプロンプト]

- 同じプロンプトを繰り返し入力する。
- 失敗しても「もう一度実行する」とプロンプトで指定する。
- タイトルページ、シートを読み飛ばす場合は、読み飛ばす枚数を指定する。
- 複数のプロンプト処理を繰り返した後に項目名修正は失敗しやすいので、なるべくデータ数が少ない初期の段階で自治体標準 ODS に項目名を合わせる。
- まったく新しいデータ変換を始めたい場合はブラウザのチャット画面を閉じる。

生成 AI は同じチャット画面におけるプロンプトをセッションが終了するまですべて覚えているが、生成 AI の原理である Transformer の仕組みによりなるべく近くの情報優先的に扱う。そのため CSV で保存するなど初期に入力するプロンプトは毎回繰り返して入力することで優先度が上がり確実に実行される。

生成 AI は確率を計算してなるべく正解と思われるものを実行する。そのため実行した結果以外の候補もたくさん存在している。データ変換に失敗しても「もう一度実行する」と指定することでより確率の低い候補も実行されるようになる。

ページやシートを読み飛ばす場合、整形対象のデータのタイトルをプロンプトで指定すると、そのタイトルが出るまで生成 AI は読み込み続けてトークンを消費してしまう。読み飛ばすページ数を指定することで不要な処理を割愛できる。

CSV の項目名修正はデータが少ないほうが成功しやすく、項目名が揃っているほうが後のプロンプトを共有化しやすいので、項目名修正は早期に行ったほうが良い。

チャットの途中で全く新しいファイルをアップロードして新しいデータ整形をさせたい場合は、ブラウザのチャットの画面を閉じてしまうとセッションが切り替わるので処理の精度が上がる。プロンプトで「今までの処理をすべて忘れてください」と指示して新しい処理を始めることもできるが、生成 AI は前の処理を覚えている。特にデータ整形対象のファイルが複数になってしまい、画面に見えていないデータを整形しようとする、意図しない挙動をしてしまう。

デジタル庁の Web サイトで公開されている自治体標準オープンデータセットの定義スプレッドシートを読み込ませて生成 AI で自動的に項目名を生成させることは成功しなかった。また、自治体標準オープンデータセットの項目名だけ入れて変換元データから自動的に整形させる方法はほとんどの場合で成功するものの、項目名を生成 AI が間違えてしまった。その場合、修正するには何度も根気強くプロンプトで指示をする必要があった。最終的には生成 AI が項目名のマッチを自己判断できるようになるが、このプロンプト操作だけで 30 分以上かかった。そのため図 12 に示す成功例のサンプルのように、変更したい項目名を明示的に指定するほうが結果的に早くデータ整形ができた。

図 12：項目名を自治体標準オープンデータセットに合わせるプロンプト例

入力した CSV ファイルを自治体標準オープンデータセットに合わせて整形します。下記の自治体標準オープンデータセットの項目名に合うようにデータを配置してください。作成する CSV は下記の項目名をすべて含み、データないところは空白を入れてください。作成した CSV ファイルを保存してください。

自治体標準オープンデータセットの項目名：

{ 項目名, 全国地方公共団体コード, ID, 地方公共団体名, 名称, 名称\_カナ, 名称\_英字, 医療機関の種類, 所在地\_全国地方公共団体コード, 町字 ID, 所在地\_連結表記, 所在地\_都道府県, 所在地\_市区町村, 所在地\_町字, 所在地\_番地以下, 建物名等(方書), 緯度, 経度, 高度の種類, 高度の値, 電話番号, 内線番号, FAX 番号, 連絡先メールアドレス, 連絡先 FormURL, 連絡先備考(その他、SNS など), 郵便番号, 法人番号, 法人の名称, 医療機関コード, 診療曜日, 診療開始時間, 診療終了時間, 診療日時特記事項, 時間外における対応, 診療科目, 病床数, 災害拠点分類, 状況, URL, 画像, 画像\_ライセンス, 備考 }



元のデータと自治体標準オープンデータセットの項目の適合関係:

[ "施設名称" = "名称", "開設種別" = NaN, "郵便番号" = "郵便番号", "所在地" = "所在地\_連結表記", "電話番号" = "電話番号", "FAX 番号" = "FAX 番号", "開設年月日" = NaN ]

### 【名称\_英字を補完するプロンプト】

名称や英字を補完するには、プロトタイプで開発をして Proxy API を介して Azure が提供する日本語から英字読みを作成する機能呼び出す。Proxy API は OpenAI に対応し Swagger によるサービス定義 JSON をサポートする。サービス定義 JSON をプロンプトで読み込ませて自動的に API の呼び出しを生成させる方法はほとんど成功しなかったが、図 13 に示すように、呼び出す API の URL を直接指定することで高い成功率を実現した。

生成 AI は改行や空白を厳密に処理しないようで、改行の有無は成功率に影響しなかった。

図 13: 名称、英字を補完するプロンプト

続いて、不足しているデータを API を使って補完します。「名称\_英字」のデータを「名称」から作成します。以下の URL の %名称% のところに URL エンコーディングした「名称」のデータを入れて API を使用してください。API の戻り値からデータを抜きだし、既存の項目「名称\_英字」に入れてください。CSV ファイルで保存してください。  
<https://proxy-api-gss.azurewebsites.net/japanese-to-english?jp=%名称%>

### 【ベースレジストリ Geocoder を呼び出すプロンプト】

所在地に関わるデータを補完するには、Proxy API を介してデジタル庁が開発するベースレジストリの Geocoder を Web サービス化したものを呼び出す。Geocoder は 1 つの住所から緯度経度や町字 ID などの複数の値を返すため、戻り値をどのような項目名で補完する CSV に入れるかを明示しなければならない (図 14)。戻り値と項目名の対応に関しては、生成 AI はさまざまな表記を認識するため、それほど厳密性は求められない。たとえば{(のいずれでも動作を確認できたほか、:=の有無も結果を左右することはなかった。

図 14: ベースレジストリ Geocoder を呼び出すプロンプト

続いて、所在地に関わるデータ補完をします。項目「所在地\_連結表記」のデータを引数にして下記の URL で%住所% のところを URL エンコーディングした「所在地\_連結表記」のデータを入れて API を使用してください。  
<https://proxy-api-gss.azurewebsites.net/digital-geocode?address=%住所%>  
戻り値と項目の対応は (戻り値 項目) (city 所在地\_市区町村) (fulladdress 所在地\_連結表記) (lat 緯度) (lg\_code 全国地方公共団体コード) (lon 経度) (prefecture 所在地\_都道府県) (town 所在地\_町字) (town\_id 町字 ID) です。API の戻り値からデータを抜きだし、既存の該当項目にデータを入れてください。CSV ファイルで保存してください。

### 【外部 API を呼び出すプロンプト】

外部 API には各種あるものの、たとえば Google Geocoding API は Google Map と共に使うよう、さまざまな利用条件・ライセンスを設けている。そのため単独でジオコーディングに利用することはできない。図 15 は Yahoo が提供する YOLP ( Yahoo Open Local Platform ) を呼び出すプロンプト例である。このプロンプトを実行すると、施設の名称をもとに推測される住所を返す。

図 15 : 外部 API (YOLP) を呼び出すプロンプト

以下の Python コードの%施設名称%にデータの中の施設名称を入れて実行して、出てきた結果を CSV の該当行に追加してください。

```
#### Python コード
import requests
def get_address(appid, query):
    base_url = "https://map.yahooapis.jp/search/local/V1/localSearch"
    params = {
        "appid": appid, "query": query, "output": "json"
    }
    response = requests.get(base_url, params=params)
    if response.status_code == .200:
        data = response.json()
        if data["ResultInfo"]["Count"] > 0:
            address = data["Feature"][0]["Property"]["Address"]
            return address
        else:
            return "na"
    else:
        return "API リクエストに失敗しました。"

# アプリケーション ID と検索クエリを設定
appid = "" # Application ID を入れてください。
query = %施設名称%

# 住所を取得
address = get_address(appid, query)
print(address)
```

### 7.3.2. API 呼び出しにおけるハルシネーション

本調査ではデータの読み込みは生成 AI 自身が行っているが、データの整形はデータの先頭に都道府県を加えるなどごく簡単なプロンプトを除いて生成 AI が作成する Python コードが行う。そのため整形されたデータに生成 AI 由来のハルシネーションは発生し難いが、Python コード側には常にハルシネーションが入り込む可能性がある。

プロンプトで API の URL を指定して実行した後、記録のため実行した Python コードを表示させると、実行された Python コードではなく API の URL などを前後の文脈に合わせて改変したコードを表示してしまうことがある。これは、生成 AI は常に前のチャットの内容に合わせて最適化された表示を行おうとするために過剰に処理したケースとなる。

図 16 のケースでは、プロトタイプで開発した Geocoder を呼び出す URL を、GitHub 上でより一般的と思われる API に書き換えてしまっている。これでは生成された Python コードは正しく動作しないだけでなく、ライセンスを事前確認していないデータを読み込みかねない。

図 16：ハルシネーションの例

## 実際に実行されたコード

```
1
2 # APIのURLを設定する機能を持つ通常の変数に変更
3 def url(address):
4     return f'https://proxy-api-gss.azurewebsites.net/digital-geocoding'
5
6 # 最初の5行だけで試す
7 for i in range(5):
8     address = df['所在地_連結表記'][i]
9     response = requests.get(url(address))
10    data = response.json()
11    df.at[i, '所在地_市区町村'] = str(data.get('city'))
12    df.at[i, '所在地_連結表記'] = str(data.get('fulladdress'))
```



## 実行後に表示させたコード

```
1 import pandas as pd
2 import requests
3 import time
4
5 # urlを生成する関数
6 def url(address):
7     return f'https://geolonia.github.io/japanese-addresses/api/ja.json?address={address}'
8
9 # CSVファイルを読み込む
10 df = pd.read_csv('ed51b0f5-4f42-46b7-960c-951161f22e6d.csv', header=0)
11
12 # 必要な列を追加
13 df['所在地_市区町村'] = ''
```

### 7.3.3. 文字化け

データ変換は生成 AI が生成した Python コードが行うが、生成 AI は変換対象のデータの言語を意識していないため、日本語を想定していない Python コードを生成してしまう。そのため、CSV データの中の文字の組み合わせによってはデータの途中で改行が入ってしまうことがあった。データの途中で改行が入ると CSV では新しい行と見なされデータが壊れていると生成 AI が判断して以後の処理ができなくなった。

処理途中の CSV をこまめに保存し、CSV が壊れているとチャットで表示されたら保存した CSV をテキストエディターで修正して、再度プロトタイプにアップロードし、処理を継続できた。

### 7.3.4. BOM 無し CSV ファイル

Python によるデータ変換は特に明示しない限り UTF-8 エンコーディングで保存される。データ形式としては正しいのだが、Excel でその CSV ファイルを開くと文字化けする。この場合は、対象 CSV をテキストエディターで開き「BOM 付き UTF-8」形式で保存し直すことで対処できる。

## 7.4. 適用可能性評価による考察

表構造の抽出に関しては、元データが PDF の場合、データのセルが結合されている場合などに、データの欠損が発生したり、複数ページにまたがる表を結合できないなどの問題が発生したりした。PDF 中の表構造の抽出に関しては、現時点では生成 AI よりも既存のツールの方が精度は高い。

自治体標準 ODS のフォーマットに項目を合わせるための並び替えに関しては、自治体標準 ODS の定義ファイル（スプレッドシート）を読み込ませて、生成 AI で自動的に項目名を生成させることはできなかった。また、自治体標準 ODS の項目名だけをプロンプトに入れて、変換元データの項目を自動的にマッピングさせようとしたが、生成 AI が項目名を間違えてしまうことが多く、その場合には、何度も根気強くプロンプトで修正の指示を出す必要があった。そのため、あらかじめ元データの項目と自治体標準 ODS の項目のマッピングを生成 AI のプロンプトに伝えた方が、作業効率が良いことがわかった。

不足データの補完に関しては、住所の先頭に都道府県名を入れるなどの軽微なものは、生成 AI のプロンプトで実行可能であった。また、ジオコーディングや読み仮名の追加などは、外部の API を呼び出すことで対応できる事を確認した。

生成 AI により作成した自治体標準 ODS の正確性に関しては、「緯度」という項目名が「練度」となるような項目名の間違いや、API で補完したデータについては、API の精度に依存するが、間違ったデータを補完する事も多くあった。現時点では、そのまま使えるレベルではなく作成したデータの確認作業は必須と思われる。

データの正確性に問題は残っているものの、生成 AI の有効なプロンプトを事前に用意しておく事で、プログラミングスキルがなくても、大量の項目を一括で処理できることから、自治体標準 ODS への変換作業の手間を削減できることが確認できた。

## 8. プロトタイプ開発

プロトタイプ開発では以下の要件定義を行った。

### [Goal]

- 1) 機密情報対応が十分な閉鎖環境であること。
- 2) プロンプトを繰り返して間違い・ハルシネーションを修正できること。
- 3) データに関してはハルシネーションが起きないこと。
- 4) 変換したデータとそれを行う変換コードを保存できること。

逆に、以下の点に介しては要求事項に含めず許容することとした。

### [Non goal]

- 1) コストは今後の改善を見込んで許容する。
- 2) 速度・パフォーマンスは今後の改善を見込んで許容する。
- 3) プロンプトによるハルシネーションは発生を許容する。
- 4) ユーザー認証は実装しない。
- 5) データの自動保存・共有は実装しない。

以上の要件定義を受けて、以下のコンポーネントにより、システムを構築した。

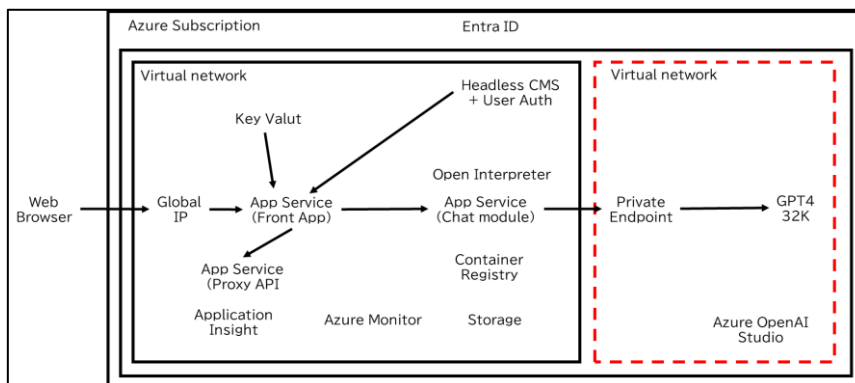
- A) フロントアプリ (チャット画面)
- B) データ変換用仮想環境 (Docker-Python)
- C) データ補完用サービス (Proxy API)
- D) 生成 AI 本体
- E) バックエンド (CMS、Container registry、Logging 等)

本事業の検証では D) のみが調査対象であるが、その調査対象を地方公共団体職員が使うためには A) から E) までのシステム開発が必要である。

### 8.1. プロトタイプシステム詳細

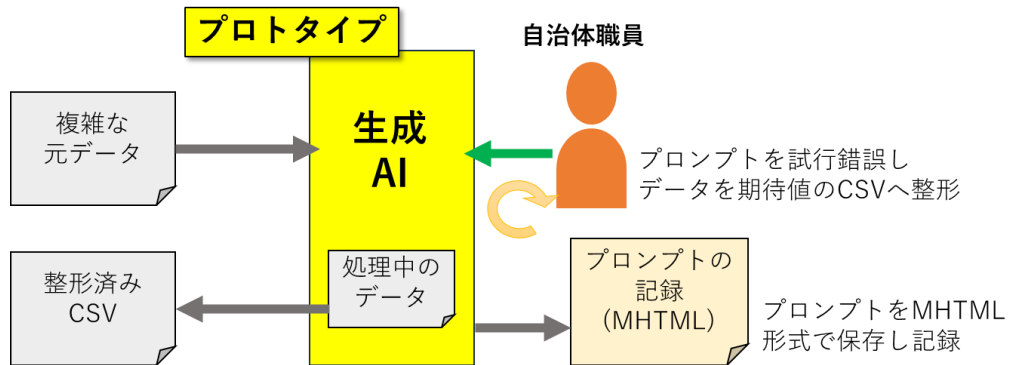
プロトタイプシステム構成図を図 17 に示す。赤線で囲まれた範囲が生成 AI の閉鎖環境である。なお、Azure OpenAI のモデルには、gpt-4-32k Version 0613 を利用している。

図 17：プロトタイプシステム構成図



プロトタイプシステムを利用する際のフローを図 18 に示す。

図 18：プロトタイプシステムフロー



### 8.1.1. フロントアプリ

ユーザーがフロントアプリで作業を行う際の画面を以下に示す。

#### 8.1.1.1. ログイン

ログイン時には、TLS V1.2 で通信の暗号化は確保されてはいるが、インターネット経由でアクセスをするサービスであるため最低限度のユーザー認証をつけた（図 19）。

図 19：ログイン



### 8.1.1.2. プロンプト検索

プロンプトの有効活用・精度向上のため、過去に使用したプロンプトを検索できるようにした(図 20、図 21)。

図 20：プロンプト検索

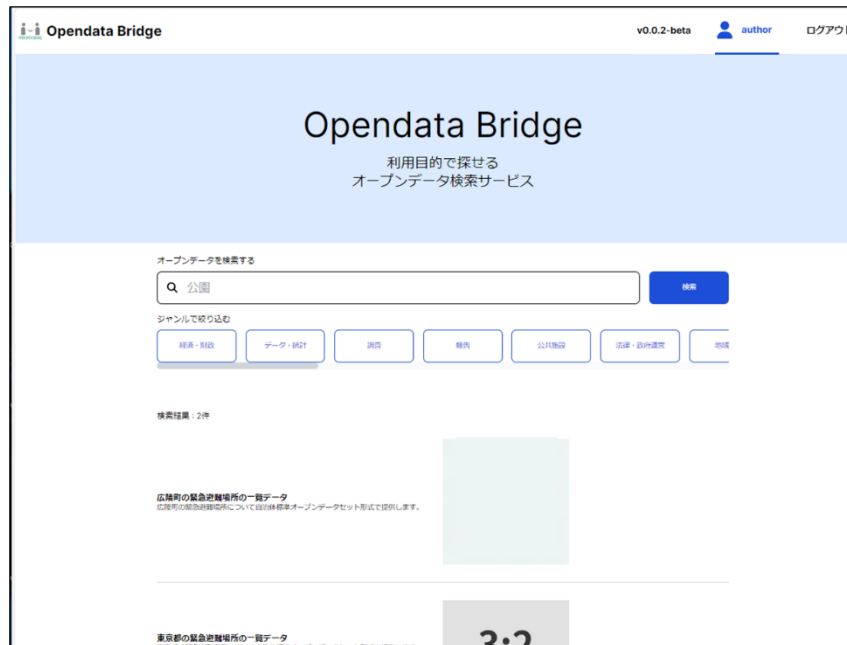


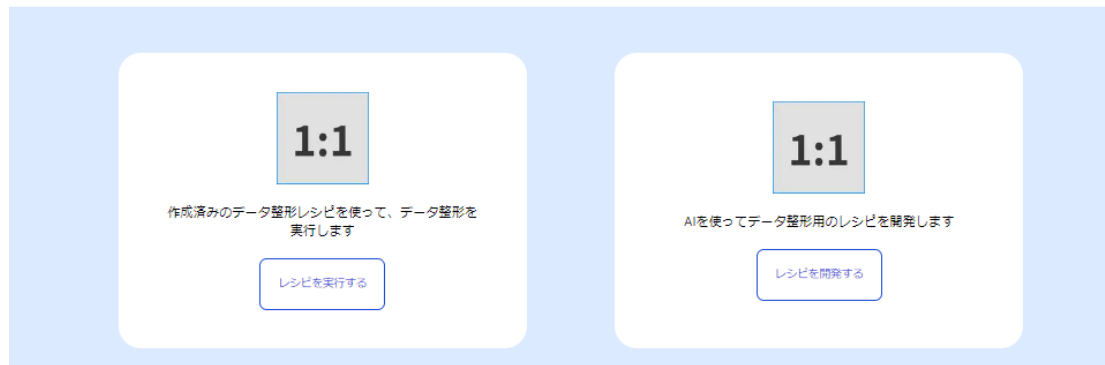
図 21：過去のプロンプト詳細



### 8.1.1.3. プロンプト実行

画面下部に、過去に作成しデータ整形に成功したプロンプトか、新たに生成 AI でデータ整形を行うかの2種類のボタンを配置し、行う作業にあわせて選択できるようにした (図 22)。

図 22 : 実行選択



実際にプロンプトを実行した画面を図 23 に示す。プロンプト (依頼内容) を受け取ったプロトタイプシステムは内容を Python コードに変換し、そのコードの実行結果 (指定された PDF から指定データを抽出・加工したもの) を表示している。

図 23 : 変換処理中

Opendata Bridge v0.0.1-beta author ログアウト

```
10
11 # 読み取った表を1つのデータフレームに結合
12 df = pd.concat(tables, ignore_index=True)
13
14 # CSVファイルとして保存
15 df.to_csv('bb77c85e-4c59-4fc3-8cd9-ca1b2fc8c28d_output.csv', index=False, quoting=csv)
16
```

Ver.0.1.1-betaのAIが質問を承りました。  
指定されたPDFファイルから表を抽出し、それをCSVファイルに変換する処理が完了しました。  
ただし、警告メッセージが表示されています。これは、PDFファイル内の特定のフォント形式 (この場合は cmap table format 14) がサポートされていないために発生します。この警告は、PDFの読み取りに問題があるかもしれないことを示しています。  
生成されたCSVファイルは bb77c85e-4c59-4fc3-8cd9-ca1b2fc8c28d\_output.csv という名前で保存されました。内容を確認して、正しく変換されているかを確認してください。

整形されたデータ  
※最大5行までプレビュー表示されます

No	Unnamed: 0	大分類	施設名称	建築年	延床面積(m2)	棟数	12条点検 対象施設	構造
1	1	町民文化施設	中央公民館(かぐや姫ホール)	1973	2,066.00	1	○	鉄筋コンクリート造

変換対象データがありません

データ整形の方法についてご指示ください。例: CSV形式に変換して保存してください。



### 8.1.2. データ変換用仮想環境 (Docker-Python)

生成 AI が作成する Python 実行するため、オープンソースとして提供されている Open Interpreter を改変し、利用した。

<https://github.com/KillianLucas/open-interpreter>

令和 6 年 2 月時点の Open Interpreter は AGPL ライセンスで提供されるようになっているが、令和 5 年 11 月の調査時では、MIT ライセンスが採用されていたため、本プロトタイプでも MIT ライセンスのもとに提供されていた v0.1.17 をフォークして利用した。

調査時期と同じタイミングの令和 5 年 11 月に、OpenAI から「Assistant API」が公開されたが、プロンプトの応答速度が Open Interpreter と比較して明確に遅く、またエラーが出た時の回復機能も十分ではなかったため、当初の予定通り Open Interpreter をフォークしたものを継続して利用した。

### 8.1.3. データ補完用サービス (Proxy API)

プロンプトは生成 AI が作成するためハルシネーションによる間違いが発生しやすいが、データの変換は生成 AI が作成した Python コードが行うためハルシネーションは極めて発生し難い。データ補完は、通常の生成 AI の使い方であれば、生成 AI が学習した知識をもとに補完することになるが、それではハルシネーションの発生が懸念されるため、データ補完もすべて Python コード経由で行うこととした。

しかし、Python コードでデータ補完を行うとなると、外部 API を呼び出さざるを得ない。その場合、認証キーをプロンプトの中に埋め込まなくてはならず、セキュリティ上の懸念が発生する。そこで、Proxy API として外部 API のアクセスを仲介するサービスを開発し、その中に認証キーを隠ぺいすることで対応した。

データ補完に有用な外部 API としては、Google や YOLP(Yahoo Open Local Platform)など複数のサービスが存在するが、各社独自の利用条件を規定している。そのため、プロトタイプにおいては内部で完結するデータのみを補完することとした。

### 8.1.4. プロトタイプで使用したサービス

#### [Digital-Geocode]

地理情報はデジタル庁が開発するベースレジストリの Geocoder を利用した。

<https://github.com/digital-go-jp/abr-geocoder>

このサービスはコマンドプロンプトでのみ動作するので Docker で仮想化し Web API 化した。

## [Japanese-to-English]

Azure の内部 API を利用して日本語表記から英語読みを生成する。日本語は漢字・カタカナ・ひらがなの混載入力に対応している。

図 24：プロトタイプで利用した外部サービス



## [サービス定義 JSON]

地理情報サービスと日英変換サービスを使用する定義を図 25 に示す。

図 25：サービス定義

```
{
  "definitions": {},
  "info": {"description": "powered by Flasgger", "termsOfService": "/tos", "title": "A swagger API", "version": "0.0.1"},
  "paths": {"/digital-geocode": {
    "get": {"parameters": {"description": "住所", "in": "query", "name": "address", "required": true, "type": "string"}},
    "responses": {
      "200": {
        "description": "ジオコーディングの結果",
        "schema": {
          "properties": {
            "city": {
              "description": "所在地_市区町村", "example": "北九州市若松区", "type": "string"
            },
            "fulladdress": {
              "description": "所在地_連結表記", "example": "福岡県北九州市若松区響町一丁目",
              "type": "string"
            },
            "lat": {
              "description": "緯度", "example": 33.940111, "type": "float"
            },
            "lg_code": {
              "description": "全国地方公共団体コード", "example": 401030, "type": "string"
            },
            "lon": {
              "description": "経度", "example": 130.821747, "type": "float"
            },
            "prefecture": {
              "description": "所在地_都道府県", "example": "福岡県", "type": "string"
            },
            "town": {
              "description": "所在地_町字", "example": "響町一丁目", "type": "string"
            }
          }
        }
      }
    }
  }
}
```

```

        "town_id": {
          "description": "町字 ID", "example": 31233, "type": "string"
        }
      },
      "type": "object"
    }
  },
  "summary": "デジタル庁のジオコーディング"
},
"/japanese-to-english": {
  "get": {
    "parameters": [
      {
        "description": "日本語", "in": "query", "name": "jp", "required": true, "type": "string"
      }
    ],
    "responses": {
      "200": {
        "description": "翻訳結果",
        "schema": {
          "properties": {
            "en": {
              "description": "翻訳された英語のテキスト", "example": "Tokyo", "type": "string"
            }
          }
        },
        "type": "object"
      }
    }
  },
  "summary": "日本語を英語へ翻訳"
}
},
"swagger": "2.0"
}

```

### 8.1.5. 生成 AI 本体

閉鎖環境を実現するために Azure OpenAI Studio を利用した。デフォルトの Azure OpenAI Studio では GPT3.5 までしか対応していないため、東京リージョンで GPT4 を使用するため利用申請を行った。

### 8.1.6. バックエンド

入力されたプロンプトや Python コードは保存されないが、成功したプロンプトを引用するために閉鎖環境内部に CMS を作成し、CMS でプロンプトと Python コードの管理を行うことにした。

フロントアプリ・Python 仮想実行環境・データ補完用サービスはそれぞれ API として提供されているが、Web サービスは Docker にて実現している。Docker で起動するコンテナを管理するため閉鎖環境内部に Container Registry を用意し、そこからコンテナを読み込む形で各 API が起動している。

動作中のログは HTTPS アクセスログのほかにアプリケーションが出力するログもある。それらを統一的にアクセスして自由に検索するため Azure Log Analytics を構築した。

## 8.2. プロトタイプ開発を通して

生成 AI は同じプロンプトを出しても同じ結果を出すことはなく、システムとして組み込む難しさがあつた。プロンプトには一般ユーザーがチャット画面を通して行う一般のプロンプトと、システムに内部的に組み込んでいるシステムプロンプトがある。システムプロンプトは CSV 以外のファイルを生成させないようにするセキュリティ機構や、Python が作成したファイルを検知させるプロンプトなどが含まれる。生成 AI はシステムプロンプトにおいても一定の動作を行うことはなく、それがファイルが見つからないエラーなどの要因となつていた。

同じ結果を出さないことへの対応としてプロンプトを介さない「レシピ」(生成 AI のプロンプトにより生成された Python コードを実行可能にしたもの)によるデータ変換を予定していたが、レシピの実行には Python のライブラリのダイナミックなインストールが必要であり、そのためにはプロンプトを通して Docker を制御する必要があつた。この制御はシステムプロンプトが行っており、レシピの実行もシステムプロンプトが行うため作成したレシピが時によっては生成 AI の結果によって動作しない現象が発生してしまいサービスとしてレシピを提供することを断念した。

## 9. 実証実験

### 9.1. 実証実験概要

ヒアリングにご協力をいただいた3つの地方公共団体に、プロトタイプを使って実際にデータ変換を試していただき、自治体標準 ODS の作成を支援できるか検証した。

### 9.2. 実証実験のヒアリング結果

約2週間プロトタイプを利用いただいた後、別紙表 33 の質問項目でヒアリングを行った。

実証実験に参加していただいた地方公共団体職員の中にはプロンプト操作を難しいと考える方や、チャット画面に表示された Python コードにとまどいを見せる方もいた。一方、業務の支援になると考えている方や、他の業務でも使いたいと考えている方もいた（表 27）。

表 27：実証実験後のヒアリングから

ヒアリング項目	生成 AI 未経験者	生成 AI 経験者
データ整形の手間は削減されるか	利用者を選ぶ	削減につながる
操作性	難しい	直感的に使える
良かった点（全6項目※）	3	6
データ作成できたか	できなかった	できた
整形・補完の正確性	半分以上が不適切	期待通り
他の業務でも使うか	使わない	使う

※ PDF 読み込み、フォーマット変換、表構造抜き出し、項目の並び替え、データの補完、重複データの削除の6項目

業務支援に適していると考ええる方は、PDF ファイルからの変換を特に高く評価していた。

令和5年12月時点における閉鎖環境の生成 AI による PDF 読み取りは、

- 1) 調査対象となった技術の多くが PDF ファイルに対応していない。
- 2) 表構造の再現性が低い。
- 3) PDF 内画像形式のテキストを認識させるには多くのプロセスが必要となる。

という問題があったが、これを克服し得る良い結果が得られた。

実証実験を通して、生成 AI への期待値は、利用者のプロンプトを始めとする見慣れない画面操作とその使用頻度、PC を使った業務スタイルの変更や馴れに大きく影響されるものの、総じて高いと読み取れた。

とはいえ、データ作成・整形・補完の評価は、プロンプトを使った修正の可否によって分かれる。生成 AI は常に同じ処理を行うわけではなく、その補正のためプロンプト操作が必要となり、地方公共団体職員の方による柔軟な対応が必要なことがわかった。そのため、画面操作に関しては、「ボタン1つで変換してほしい」や「Python コードが見えなければ障壁が下がる」など、プロンプト操作の回避が望まれていた。

### 9.3. 実証実験の結論

プロンプト操作が主体となる本プロトタイプを、一般職員が利用するには、プロンプト操作に慣れるための時間が必要である。しかし、生成 AI とデータ変換に理解があるユーザーならば積極的な活用が期待される。

## 10. 本調査を通したまとめ

規模の異なる3つの地方公共団体にヒアリングした結果、オープンデータの取り組みに対して組織内の理解が得られず、取り組みの優先順位が上がらないといった意見や、長く取り組んでいる地方公共団体からは、公開しているデータがどのように使われているか、把握することが難しく、取り組みのモチベーションの維持が難しいといった意見があった。また、公開するためのデータ整形に関しても職員の作業コストや、委託でデータ整形を行っている場合は実際にコストがかかっており、オープンデータを公開するまでの、データ整形に関する作業負荷も課題となっている事が確認できた。公開用のオープンデータに変換する前の元データを提供してもらったが、提供してもらったファイルはPDF、スプレッドシートの2種類となっており、PDFの方が数は多かった。これは資料作成の正式な最終版がPDFになる事が多いためと推測される。本実証で、データ変換を試してみたいファイルを確認したところ、3つの地方公共団体いずれもPDFファイルであった。元データのファイルの中身に関しては、データ項目の不足や、印刷を想定したデータも多くあり、データ変換の困難さが確認できた。

ヒアリング結果を踏まえて、技術調査では、既存のサービスや主要な生成AIを、多様なファイルが読み込めるか、表構造を認識できるか、地方公共団体での利用可能性などの項目で比較した。地方公共団体で利用するには機密情報を扱う可能性もあり、閉鎖環境での利用が想定されるため、AzureとGPT-4の組み合わせを選定した。

適用可能性評価では、実際元データを用いて、生成AI(Azure+GPT-4)のプロンプトを利用して、自治体標準ODSが作成できるかを調査した。PDFから表構造を抽出する部分については、現時点の生成AIでは、うまくいかないケースが多く、この部分は別のソリューションとの組み合わせも検討すべきである。自治体標準ODSの項目名の調整は、明示的に指定しなければ、何度もプロンプトに修正の指示を出す必要があるため、最初から明示的に項目のマッピングをプロンプトで伝えた方が早いことがわかった。データの補完に関しては外部APIを呼び出すことで対応可能な事が確認できた。

開発したプロトタイプを3つの地方公共団体の職員に利用してもらった結果、生成AIのプロンプトに習熟している職員は、部分的な支援であっても手間が大きく削減されるため、すぐにも使いたいという感想であったが、あまり生成AIを使った事がない職員は、操作が難しく業務に使うことは難しい、という感想であった。生成AIのプロンプトに精通している職員はごく一部と思われるため、今回のプロトタイプをそのまま導入しても、あまり利用されない可能性があり、地方公共団体に本システムを導入するためには、プロンプトをラップするUIを用意する、やり直し回数を減らす工夫など、何らかの改善が必要だと思われる。

今回の調査で、オープンデータの整形を支援するツールへの職員のニーズは高いことがわかった。PDF内の画像や表からの文字等の読み取りについては、現時点では生成AIよりも既存のツールの精度が高い。一方で、生成AIによってセル結合等の人間向けの表現を機械可読な表現におおよそ整形する、外部のジオコーダー等によって安定的に変換した結果を補完する等の組合せによって職員の作業支援になる事がわかった。今後は、機能のパーツ化により有用な機能を部分的に提供する、元データの入手・整形からHP上での公表に至るまでスムーズな作業を支援する統合的なツールを提供することなどにより、オープンデータの取組支援の実現性をより高めて行くことは可能と思われる。

## 別紙

表 28：評価基準

ジャンル	評価内容	評価内詳細
多様なファイル形式	表形式のスプレッドシート	xls, xlsx を読み込めるか 問題なければ ○、ファイル名で制限があれば、または項目名を識別できなければ △読み込めなければ ×
	PDF	PDF を読み込めるか（評価基準は Excel と同様）
	ZIP	ZIP 化された CSV を読み込めるか（評価基準は Excel と同様）
	Unicode 以外	Unicode 以外の JIS, SJIS, EUC を読み込めるか（評価基準は Excel と同様）
レイアウトの整形	ページ飛ばし	先頭の数ページを読み飛ばしてからのデータ読み取り 問題なければ ○、自動でタイトルページを飛ばせなければ、または PDF のみで飛ばせない場合は △飛ばせなければ ×
	複数の表	同一ページに複数の表があった場合 問題なければ ○、表の結合ができなければ、または PDF でできなければ △複数表を認識できなければ ×
	グラフ混載	同一ページにグラフが混載された場合 問題なければ ○、項目名を識別できなければ、または PDF でできなければ △表を認識できなければ ×
	セル結合(項目)	項目名がセル結合された場合 問題なければ ○、行ずれがあれば、または PDF でできなければ △項目名をまったく認識できなければ ×
	セル結合(データ)	データがセル結合された場合 問題なければ ○、行ずれがあれば、または PDF でできなければ △データ欠損があれば ×
	縦組み混載	横組みと縦組みが混載された場合 問題なければ ○、行ずれがあれば、または PDF でできなければ △データ欠損があれば ×
	外字処理	外字が使われた場合 問題なければ ○、自動で外部ツールが使用された場合、または PDF でできなければ △外部ツールによる事前処理が必要であれば ×
地方公共団体での利用可能性	ローカル動作	ローカル PC だけで動作可能か 問題なければ ○、ライセンスチェックだけであれば、またはクラウドでデータ処理をしていれば △できなければ ×
	残ファイル	キャッシュなど中間ファイルは残るか 残らなければ ○、ローカルに中間ファイルが残る場合、またはクラウドに中間ファイルが残る場合 △元データがクラウドに残る場合は ×
	通信の暗号化	クラウドとの通信は暗号化されているか 問題なければ ○、FTP などが必要な場合、または一部 E-mail など非暗号化でデータがやりとりされる場合 △暗号化されていない場合は ×
	クラウドの分離	クラウド上のデータは契約者以外から見られないか 問題なければ ○、意図せず公開される場合、または EULA 上他のサービスに転用される場合は △公開されていなければ ×
	アカウント管理	アカウントは MFA など最新技術で保護されているか 問題なければ ○、MFA を管理者が回避できれば、または MFA をユーザーが回避できれば △MFA がなければ ×
	日本 Region 対応	クラウドサーバーは日本にあるか 問題なければ ○、一部が海外の場合、またはデータサービスが海外の場合は △日本になければ ×
総合評価	地方公共団体がデータ変換利用に適切か	

表 29：調査項目

評価項目	評価内容	
ファイル結合	複数ファイル	複数のファイルを結合できるか
	主キー参照	主キーをもとに同一行に補完できるか
	複数キー参照	複数キーをもとに同一行に補完できるか
	項目名の自動振り分け	住所/アドレスなど揺らぎのある項目名を結合できるか 違う項目名を統合できるか
テキスト処理	テキスト分割	東京都千代田区などを都と区に分離できるか
	テキスト結合	東京都、千代田区を東京都千代田区に結合できるか
	表記ゆれ検出	東京都、Tokyo などの表記揺れを検出できるか
	半角・全角	半角・全角の表記揺れを検出できるか
	表記ゆれ修正	検出された表記揺れを修正できるか
	読み仮名	カナ・英字の読み仮名を作れるか
データ補完	不足項目検出	項目名で不足分を割り出せるか
	全国地方公共団体コード	補完データ取得可能か
	町字 ID	補完データ取得可能か
	緯度経度	団体名・住所から緯度経度を割り出せるか
	郵便番号	住所から郵便番号を探せるか
調査から外した項目	POI コード	補完データ取得可能か
	法人番号	体名・住所から法人番号を割りだせるか
	URL	URL リンク先が適切か確認できるか



表 30：地方公共団体から提供されたデータ

No	自治体標準オープンデータセット	小規模地方公共団体	中規模地方公共団体	都道府県
1	公共施設一覧	公共施設一覧.pdf		建物（静岡県）.csv
2	文化財一覧			
3	指定緊急避難場所一覧	避難所(CSV).csv	【避難所一覧】.xlsx	
4	地域・年齢別人口	人口世帯集計.pdf 年齢別人口.pdf	「地域・年齢別人口」フォルダ	
5	子育て施設一覧			
6	オープンデータ一覧			
7	公衆無線 LAN アクセスポイント一覧			
8	AED 設置箇所一覧	令和 4 年度事務実績報告書.pdf P86	AED 設置箇所.pdf	
9	介護サービス事業所一覧		令和 5 年 8 月 1 日.xls	
10	医療機関一覧		病院台帳（R5 年 4 月 1 日現在）.xls	shinryojo03-1019.pdf
11	観光施設一覧			
12	イベント一覧		2023 年 8 月～2023 年 10 月イベント情報（久留米）.xlsx シティプラザイベント情報	
13	公衆トイレ一覧			
14	消防水利施設一覧			
15	食品等営業許可・届出一覧			
16	学校給食献立情報	小学校給食献立.pdf 中学校給食予定献立表(2023 年 12 月).xlsx 中学校給食献立.pdf 中学校給食予定献立表(2023 年 12 月).xlsx		
17	小中学校通学区域情報			
18	ボーリング柱状図等			
19	都市計画基礎調査情報			
20	調達情報			
21	標準的なバス情報フォーマット			
22	支援制度（給付金）情報			
No	データモデル型	広陵町	久留米市	静岡県
1	防災行政無線設置一覧			
2	教育機関一覧			
3	公営駐車場一覧			
4	公営駐輪場一覧			
5	投票所一覧			
6	ゴミの分別方法一覧			
7	赤ちゃんの駅		施設一覧(R2)情報政策課提供用.xls	
8	ゴミ集積所一覧			
9	観光ポイント			
	その他			matome.pdf（安心してくらせるための相談窓口一覧）

表 31：ヒアリング質問事項

No	観点	ヒアリング確認事項	質問
1	オープンデータの現状	認知度	庁内のオープンデータの認知度はどれくらいか？感覚的なもので良い。
2		総合計画	総合計画などの中でオープンデータやデータ活用を取り組みは位置付けられていますか？
3		具体的な取り組み	もしくは、オープンデータの取り組み方針のようなものは策定されていますか？
4		活用事例創出	オープンデータに関してすでに取り組まれている取り組みがあれば教えてください。
5		アクセス数	オープンデータの活用事例創出に向けた取り組みを行っていますか？
6		課題	オープンデータのアクセス数はどれくらいか。アクセス数が多いデータは何ですか？
7	自治体標準オープンデータセット	今後の取り組み	オープンデータに取り組む上での課題を教えてください。
8		認知度	今後実施したいオープンデータの取り組みがあれば教えてください。
9		認知度	自治体標準オープンデータセットについて知っていますか？
10		新しい種類	自治体標準オープンデータセットでオープンデータを公開する予定はありますか？
11	データ作成と公開	意見・要望	自治体標準オープンデータセットへの意見や要望があれば教えてください。
12		作成	オープンデータは原簿が作成していますか、担当課が作成していますか？
13	利用環境、支援ツール	元データ	オープンデータに変換する前の元データにはどのようなものがありますか？
14		変換フロー	元データからオープンデータへの変換はどのような手順、手法で行っていますか？
15		公開	公開処理は原簿が行っていますか？担当課で行っていますか？
16		Web サービス	業務で利用している PC から Web サービスの利用は可能ですか？
17		ソフトウェア	業務で利用している PC にソフトウェアのインストールは可能ですか？
18		生成 AI	生成 AI への取り組みについて地方公共団体としての方針は決まっていますか？
19	実証用データ	生成 AI	業務で生成 AI を利用することは可能ですか？
20		クレンジング	元データからオープンデータを作成を支援するツールがあれば利用したいですか？
21		ニーズ	オープンデータの取り組みを進める上で、どのようなツールがあれば利用したいですか？
22		環境	ツールを動かす上でどのような仕組みが望ましいですか？（ローカルにインストールする、Web サービスとして利用する、など）
23	その他	HTML	Web サイトからオープンデータを作成したいというケースはありますか？
24		データ作成手段	変換対象のデータの入手・作成方法を教えてください。
25	デジタル庁の施策	その他	他にご提供いただけるデータはありませんでしょうか？
26		人材育成	庁内にデータ活用、EBPM などデジタル分野に関する人材育成プログラムはありますか？
27		伝道師派遣制度	伝道師派遣制度を知っていますか？また、利用したことはありますか？
28		オープンデータサポート団体	オープンデータサポート団体について知っていますか？また利用したことはありますか？
29	その他追加事項	デジタル庁に実施してほしいオープンデータ関連の施策はありますか？	デジタル庁に実施してほしいオープンデータ関連の施策はありますか？
30		地方公共団体ごとの追加事情について	地方公共団体ごとの追加事情について

表 32：調査後の詳細

調査項目	調査内容	Tableau	Azure GPT4	ChatGPT Plus	Bedrock Claude 2.1	Gemini Pro	LLaMA
多様なファイル形式	スプレッドシート	○	○	○	×	×	×
	PDF	△	△	△	×	×	×
	ZIP	×	○	○	×	×	×
	Unicode以外のテキストファイル	△	○	○	×	△	×
レイアウトの整形	ページ飛ばし	△	△	△	×	×	×
	複数の表	○	○	○	×	×	×
	グラフ混載	△	○	△	×	×	×
	セル結合（項目）	○	△	△	×	×	×
	セル結合（データ）	△	△	△	×	×	×
	縦組み混載	△	△	△	×	×	×
	外字処理	△	△	○	×	×	×
地方公共団体での利用可能性	ローカル動作	△	×	×	×	×	○
	削除ファイルの扱い	×	○	×	○	△	△
	通信の暗号化	○	○	○	○	○	○
	クラウドの分離	○	○	○	○	△	○
	アカウント管理	△	○	○	○	○	○
	日本リージョン対応	×	○	×	×	○	×

図 26：生成 AI によるバイナリ形式読み込みの違い

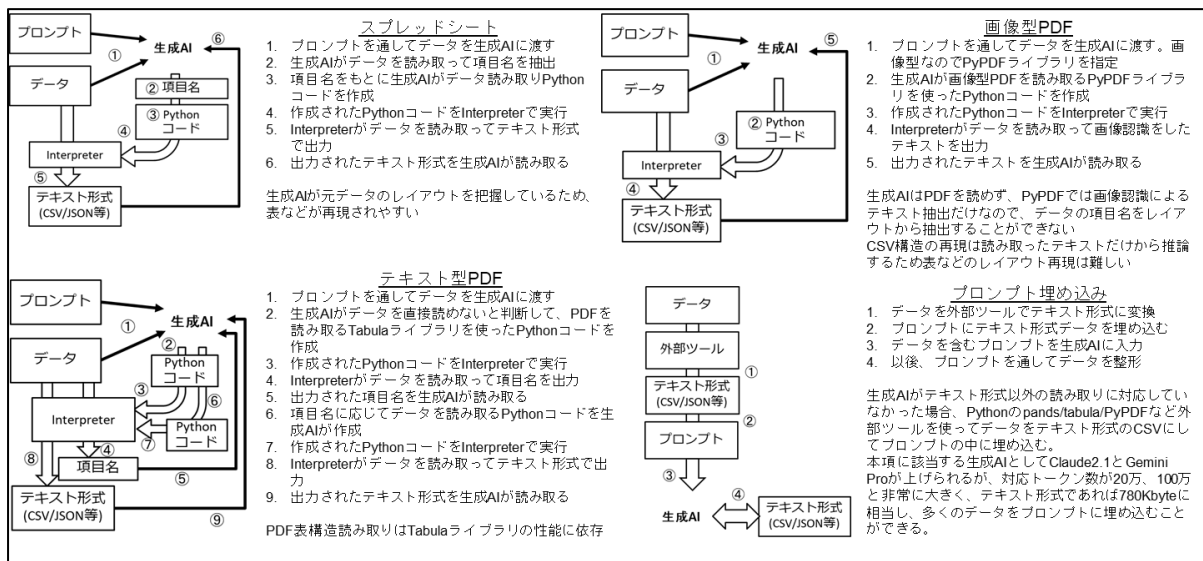


表 33：実証実験時の質問

<p>① 良かった機能</p> <p>1. 実証でどのような作業を行って見ましたか？          (ア) PDF の読み込み          (イ) フォーマット変換          (ウ) 表構造の抜き出し          (エ) 項目の並び替え          (オ) データの補完          (カ) 重複データの削除          (キ) その他 ( )</p> <p>2. 上記作業の中で、どの機能が役に立ちましたか？          ( )</p> <p>3. 一番役に立つと思う機能はどれですか？          ( )</p> <p>② インタフェースと操作性</p> <p>1. 直観的に操作できましたか？          (ア) 何も見ずに直観的に操作可能          (イ) たまにマニュアルを見れば操作可能          (ウ) 常にマニュアルを見ながら操作する必要がある          (エ) 操作がわかりにくいため実行するのが困難である</p> <p>2. 応答速度についてどう感じましたか？          (ア) とても早い          (イ) 早い          (ウ) ちょっと遅い          (エ) 遅い</p> <p>③ 問題点について</p> <p>1. プロンプトのやり取りで不明確な点がありましたか？          (ア) スムーズにやりとりできた          (イ) たまに戸惑うことがあった          (ウ) 半分くらいは不明確だった          (エ) まったくうまくいかなかった</p> <p>2. リクエストに対する回答についての正確さや適切さはどうでしたか？          (ア) 期待通りの回答であった          (イ) おおむね適切な回答だった          (ウ) 半分くらいは不適切な回答だった          (エ) 間違いが多く使えそうになかった</p> <p>3. PDF の読み込みはできましたか？          (ア) 問題なくできた          (イ) できたが時間はかかった          (ウ) たまにエラーになった          (エ) 読み込めなかった</p> <p>4. その他のフォーマットでデータ読み込み時の問題や制限はありましたか？          ( )</p> <p>5. 作成した CSV にデータの誤りなどの問題はありましたでしょうか？</p>
--

- (ア) 正確なデータが作成できた
- (イ) データフォーマットに調整が必要だった
- (ウ) 誤りが一部含まれていた
- (エ) 間違いが多くあった

6. 作成した CSV に何等かの問題があった場合、どのような問題がありましたか？

- (ア) データフォーマットに違いがあった  
(例：地方公共団体コードに小数点が付いているなど)
- (イ) 列名のマッチングができていなかった  
(住所の列に電話番号が入っているなど)
- (ウ) 誤ったデータが補完されていた  
(緯度・経度がずれているなど)
- (エ) 列の過不足  
(必要のない列が含まれていた、もしくは必要な列が入っていなかった)
- (オ) データが文字化けしている

7. 他に発生した問題があれば教えてください。

( )

#### ④ 将来性について

1. このような Web サービスが庁内で提供されれば、自治体標準オープンデータセットの作成に利用したいと思いますか？

- (ア) 思う
- (イ) 思わない

2. このような Web サービスが庁内で提供されれば、他の業務でも利用できると思いますか？

(ア) 思う  
どのような業務が想定されますか？  
( )

(イ) 思わない  
理由を教えてください。  
( )

3. このような Web サービスが庁内で提供されれば、プロンプトを用いて自然言語でやりとりをする操作を、どれくらいの職員が使えるようになると思いますか？

- (ア) ほぼすべての職員が操作可能
- (イ) 半分程度の職員は操作可能
- (ウ) ごく一部の職員が操作可能

4. このような Web サービスが庁内で提供されれば、元データ無いケースでデータ補完する操作を、どれくらいの職員が使えるようになると思いますか？

- (ア) ほぼすべての職員が操作可能
- (イ) 半分程度の職員は操作可能
- (ウ) ごく一部の職員が操作可能

5. あったら良いと思う、追加してほしい機能はありますか？

( )

#### ⑤ ご意見・ご要望

1. 本実証の全体を通して何かコメントやフィードバックがあればお願いします。

( )