

地域特性がヘルスケア施設の売上に与える影響 — マルチモーダル地理データ統合による実証分析 —

東京大学大学院 情報理工学系研究科

増田 俊太郎

東京大学大学院 情報理工学系研究科

山崎 俊彦

要約

本研究は、衛星画像と Large Multimodal Model (LMM) を活用して地域の潜在的特徴を抽出し、ヘルスケア施設の売上予測性能を改善することを実証した。90 件の小規模な売上データに対し、衛星画像から抽出したエリア種類比率や地域の定性評価等の潜在的特徴、道路ネットワーク、人口統計等の多種データ (104 特徴量) を収集し、4 段階の特徴量選定プロセスにより探索的に効果的な特徴量を特定した。16 パターンの売上予測タスクで検証した結果、衛星画像統合により対称平均絶対パーセント誤差 (sMAPE) が平均 4.2 ポイント改善、決定係数が 0.144 改善、全パターンの 75-87.5% で性能向上を確認した。SHAP 分析により、立地や診療科によって売上を左右する要因が異なることを特定した。保険診療では都会度合いや周辺エリアの特徴、自費診療では人の移動の活発さや出店先施設が重要な影響要因として抽出された。

キーワード

ヘルスケア施設, 売上予測, 衛星画像解析, マルチモーダルデータ, 立地戦略

1. はじめに

ヘルスケア施設の経営において、立地選定は事業の成功を左右する戦略的意思決定である。医療クリニックは一度開業すると移転が困難であり、初期の立地選択が長期的な収益性に決定的な影響を与える。しかしながら、多くの立地決定は経験則や主観的判断に基づいており、データに基づく科学的な意思決定支援システムの導入は遅れている (丹生, 2008; 荒川他, 2018)。医療施設経営の成功には、人口密度や交通利便性などの定量的要因だけでなく、地域コミュニティの特性や生活パターンといった定性的要因の理解が不可欠である (Park et al., 2024; Okengwu et al., 2022)。しかし、こうした複合的な地域特性の把握には専門的な現地調査が必要となる。さらに、医療分野特有の課題として、プライバシー保護や情報管理の観点から経営データへのアクセスが制限され、十分なサンプルサイズの確保が困難という状況がある。

この課題に対し、衛星画像解析技術と Large Multimodal Model (LMM) の進展が新たな可能性を提示している。衛星画像を用いた社会経済的特徴の抽出は、アフリカにおける貧困予測 (Jean et al., 2016) や経済活動の推定 (Yeh et al., 2020)、スラム街での詳細な経済分析 (Marx et al., 2019) などで実績を上げている。特に LMM の活用により、「住宅密集地域」「商業活動が活発なエリア」といった、従来は専門家の現地調査でしか得られなかった定性的な地域理解を、画像から直接抽出することが可能となりつつある。しかしながら、こうした新技術をヘルスケア施設の経営分析に適用した研究は限定的である。特に、小規模サンプルという制約下で、衛星画像から抽出される高次元かつ抽象的な特徴量を、いかに効果的に売上予測モデルに組み込むかは未解決の課題として残されている。

本研究では、マルチモーダル地理データの統合により、小規模データセットでも高精度なヘルスケア施設の売上予測を実現する手法を提案する。具体的には、(1) 衛星画像、人口統計、道路ネットワーク等の異種データを統合する予測フレームワークを構築し、(2) 多段階の特徴量選定により過学習を抑制しつつ予測性能を最大化する手法を開発し、(3) SHAP (Lundberg & Lee, 2017) 分析により、売上に寄与する地域特性を解明し、エビデンスに基づく立地戦略の指針を提示する。

II. 関連研究

1. 売上予測研究の動向

売上予測は商業・サービス業において重要な研究分野として発展してきた。従来手法では、人口密度、年齢構成、所得水準、交通アクセスなどの定量的要因に基づく統計的分析が主流であった (Giering, 2008; Park et al., 2024)。例えば店舗の複数商品の日次売上データに対して Singular Value Decomposition (SVD) を用いた行列補完による売上予測が行われ (Giering, 2008)、小売チェーン店での実用的な成果が報告された。

近年では時系列予測手法が発展し、深層学習を活用した高度なモデルが開発され (Salinas et al., 2020; Oreshkin et al., 2020; Lim et al., 2021)、M5 Competition (Makridakis et al., 2022) などの大規模売上予測コンペティションでその有効性が実証された。日本においても小売店やスーパーマーケットチェーンを対象とした売上予測研究が報告されている (丹生・松本, 2008; Liu et al., 2017)。

2. ヘルスケア施設に関する研究

ヘルスケア施設の立地選定と売上予測に関する研究は、一般的な施設と比較して限定的である。これは主に、医療経営・売上データの入手が困難であることとプライバシー保護による制約が起因している (Park et al., 2024)。

既存研究では、患者需要予測 (Maddigan & Susnjak, 2023)、外来患者数予測 (Williams et

al., 2009), 閉院予測 (Park et al., 2024) などが報告されている。しかし, 経営的観点からの売上予測モデルは十分に確立されておらず, 「日本におけるクリニック経営」という限定された領域ではノウハウがほぼ蓄積されていない。

3. 衛星画像を活用した地域特性分析

知見が蓄積されていない当該分野において, クリニック売上に強く影響する要素を特定するには, 広域から探索的にデータの関連性を見つけ出す必要がある。関連するアプローチとして, 近年, 衛星画像を活用した手法が提案されている。Jean et al. (2016) は衛星画像と機械学習を組み合わせることで貧困レベルを予測し, Yeh et al. (2020) はアフリカにおける経済的指標の推定に深層学習を活用した。これらの研究は, 衛星画像から抽出される空間的特徴が, 地域の社会経済的特性と強い相関を持つことを実証している。また, Marx et al. (2019) は, 経済活動が捕捉しづらく詳細なデータが手に入りにくいスラム街を対象に, 高解像度の衛星画像から屋根の特徴を抽出し, ミクロレベルでの経済活動指標との高い相関を示した。この研究は, 衛星画像から得られる視覚的特徴が, 従来の統計データでは捉えきれない地域特性を定量化し, 地域経済を紐解く可能性を示している。

これらの画像の分析は ResNet (He et al., 2016), Vision Transformer (Dosovitskiy et al., 2021) などの確立された深層学習モデルにより, 高精度な画像特徴抽出が可能となった。また, CLIP (Radford et al., 2021), BLIP (Li et al., 2022) などのビジョン・言語モデルは, 画像と言語の統合的理解を実現し, 画像から意味的な情報を抽出することを可能にした。さらに, 大規模言語モデル (LLM) の登場により, 画像から「閑静な住宅街」といった人間の直感的な地域理解に近い定性的記述を自動生成することが可能となった (OpenAI, 2023)。GPT-4o や LLaVA (Liu et al., 2024) に代表される高精度な Large Multimodal Model (LMM) の活用により, 従来捕捉しづらかった領域での経済活動をより広く, 深く, 低コストで分析できる可能性が高まっている。

4. 研究ギャップと本研究の位置づけ

先行研究の分析から, 以下の研究ギャップが明らかになった: (1) ヘルスケア施設に特化した売上予測手法と知見の不足, (2) 同領域における小規模・多種データソースの統合的・探索的活用手法の未確立。本研究では, これらのギャップに対し, LMM を活用した衛星画像からの地域特性抽出と, 多段階特徴量選定プロセスを組み合わせた新しい効果的なアプローチを提案する。また, ヘルスケア施設における売上に影響する地域特性を特定することで, 当該業種, および他業種施設に関連する知見も提供する。

III. 研究手法

1. 研究概要

本研究では、日本全国の 90 件の医療クリニックを対象に、マルチモーダル地理データを統合した売上予測手法を提案する。一般的な売上予測に用いられる地理・人口統計等のデータに加え、衛星画像から抽出した地域特性を活用することで、従来捕捉困難であった地域情

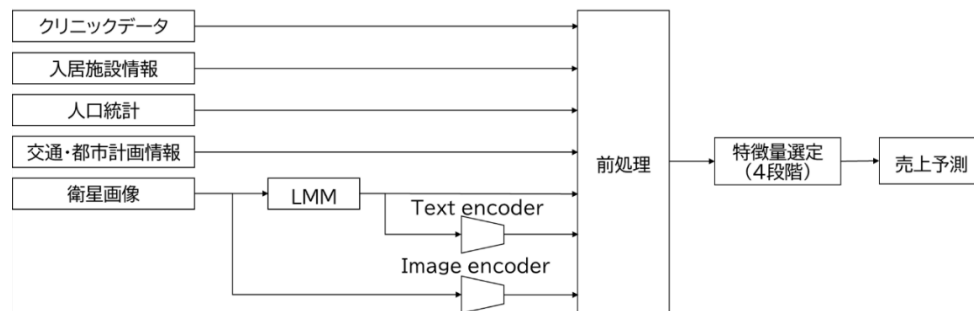


図 1 提案手法の全体像

報を定量化し、予測精度向上を図る。図 1 に提案手法のパイプラインを示す。本研究ではクリニックデータ、クリニックが入居する大規模施設（入居施設）のデータ、人口統計、交通・都市計画情報、衛星画像を用いて売上予測をする。小規模・多種データソースを利用するため、特徴量選定を 4 段階設定して最終的な予測に至る。

2. データ収集

(1) クリニックデータ

本研究は 90 クリニックの基本情報（診療科、住所、専有面積）および 2008 年 5 月～2024 年 8 月の月次売上データをベースとして売上予測を実施する。季節性や売上変動を最小化するため、最低 1 年以上の売上データを有するクリニックのみに絞り込み、2024 年の平均売上を使用する。多くの診療科で保険診療が売上の主要部分を占める一方、保険適用外の診療（美容関連等）は自費として請求される。これら 2 つの売上源は形成メカニズムや価格設定の自由度が異なるため、それぞれ個別に分析する（保険診療売上： R_{ins} 、自費診療売上： R_{oop} ）。また、売上とクリニックが入居するエリアの専有面積との間に強い関連性が観察されたため、面積当たり売上指標（保険／自費診療売上：それぞれ R_{ins_area} 、 R_{oop_area} ）も算出する。また、クリニックが大規模ショッピングセンター（以下 SC）内の 1 区画に入居しているか、それ以外に立地しているかによっても売上傾向に差が見られた。そのため、立地についても SC 内／全立地でタイプを分けて分析する。合計 16 パターンの条件でそれぞれ売上予測モデルを構築する。

(2) 入居施設データ

クリニックが入居する SC に関するデータとして、SC 面積、区画数、年間売上、駐車台数、来店者数を収集して利用する。

(3) 人口統計データ

令和 2 年国勢調査データ（総務省統計局, 2022）を利用する。市区町村単位の従業地・通学地統計により算出したネットワーク中心性（ページランク、固有ベクトル中心性、次数中

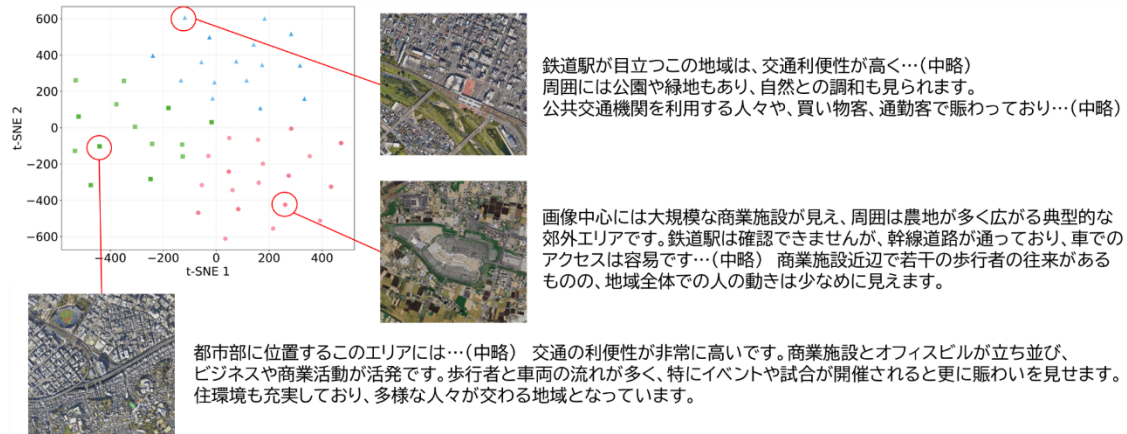


図 2 GPT-4o による衛星画像定性評価テキストと t-SNE によるテキスト特徴量の可視化

心性) が主な利用データである。

(4) 都市計画関連データ

国土交通省が公開する不動産情報ライブラリ API から、用途地域、建ぺい率、容積率、地価公示価格を取得し、地域の土地利用規制や経済的価値を反映する指標として使用する。

(5) 交通関連データ

対象立地のアクセス性に関わるデータとして、OpenStreetMap¹ (以下 OSM) から取得できる道路ネットワークデータを利用する。OSM は全世界を対象とした地図データを公開しており、ユーザーにより編集可能な仕様になっている。OSM が提供する高密度な道路ネットワークデータを用い、道路や交差点の中心性を算出して予測に利用する。

(6) 衛星画像由来データ

Google Maps Platform の Maps Static API を用い、対象クリニックを中心点とした約 1.2km 四方の衛星画像を取得する。取得した衛星画像からクリニック周辺の地域特性を取得するため、OpenAI 社が提供する GPT-4o を用いて、衛星画像から 13 種類の体系的な地域特性を抽出した。これには、大規模施設の有無、駅・幹線道路の有無、都市部/郊外の分

¹ OpenStreetMap. <https://www.openstreetmap.org/>, [2025, 6, 24, accessed]

類（バイナリ特徴4項目）、建物密度、緑地率、道路率、エリア種類別比率、建物高さ分布、古い建物比率（比率特徴6項目）、推定歩行者通行量、推定交通量（スケール特徴2項目）、地域の定性評価（テキスト300字）が含まれる。特徴抽出のためのプロンプトは、画像解析の専門家としてのロールを与える system message と、各特徴を出力させるための user message（例：「画像の中に鉄道駅があるかどうか」などと判断基準を設定した。図2は GPT-4o により抽出した地域の定性評価（テキスト）の事例である。これを見ると、衛星画像から駅、幹線道路、スタジアム、自然環境等の存在を正確に読み取り、そこから推定される人の活動や地域特性をテキストで出力できることが確認できる。

また、LLM とは別で、衛星画像から直接事前学習済みモデル（ResNet-50, CLIP, BLIP, Vision Transformer）を用いて抽出した高次元画像特徴量と、GPT-4o で抽出した定性評価テキストから日本語 BERT を用いたテキスト特徴量も利用する。予備実験の結果、どちらもクリニックデータ数に対して高次元すぎるため回帰に直接寄与しなかった。そこで、主成分分析（PCA）により 1~10 次元の複数パターンに次元削減し、最適な次元数を特徴量選定プロセスで決定した。

3. 特徴量選定プロセス

本研究では、予測モデルとしてサポートベクター回帰（SVR）を採用した。SVR は少数サンプルに対して頑健であり、非線形関係を柔軟にモデル化できる利点がある。収集した 104 の特徴量から、多段階選定プロセスにより各予測タスクに最適な特徴量組み合わせを決定した。特徴量選定は次の 4 段階で構成される：(1) 相関クラスタリングによる多重共線性の除去、(2) Stability Selection (3) Sequential Floating Forward Selection (SFFS) (4) Grid Search による組み合わせ最適化。(1)では階層的クラスタリングにより高相関（閾値 0.9）の特徴量群から代表 1 つのみを選定した。(2)ではブートストラップサンプリングと Elastic Net 正則化を組み合わせ、選択頻度上位 30 件の特徴量を選定した。(3)では SFFS アルゴリズムにより特徴量を 10 件に絞った。(4)では Grid Search により特徴量の全組み合わせを検証し、最も予測性能が高い特徴量の組み合わせを特定した。最終的に Leave-One-Out 交差検証（LOOCV）を行い、ハイパーパラメータを調整した。

4. 特徴量選定の解釈

予測に寄与する地域特性を明らかにするため、SHAP（SHapley Additive exPlanations）分析を実施した（Lundberg & Lee, 2017）。SHAP 値は協力ゲーム理論に基づき、各特徴量 j の予測への貢献度 ϕ_j を定量化する：

$$\phi_j = \sum_{S \subseteq N \setminus \{j\}} \frac{|S|! (|N| - |S| - 1)!}{|N|!} [f_{S \cup \{j\}}(x_{S \cup \{j\}}) - f_S(x_S)]$$

ここで N は全特微量の集合、 S は特微量の部分集合、 f_S は特微量集合 S のみを用いた予測関数である。

IV. 実験

1. 実験条件

衛星画像由来データの有効性を検証するため、売上予測実験では同一条件下で衛星画像由来データあり/なしで構築したモデルの性能を比較する。モデルに用いる SVR のハイパ

表 1 提案手法によるクリニック売上予測結果。有/無は衛星画像由来データの利用有無、向上率は衛星画像由来データ利用の無→有での性能向上率を示す

診療科	立地	予測対象	sMAPE (↓)			R ² (↑)			Rank Corr. (↑)		
			無	有	向上率	無	有	向上率	無	有	向上率
歯科	SC	R _{ins}	31.31	23.04	26.4%	0.201	0.440	118.9%	0.638	0.849	33.1%
歯科	SC	R _{oop}	69.48	73.69	-6.1%	0.291	0.485	66.7%	0.574	0.799	39.2%
歯科	SC	R _{ins_area}	24.96	23.06	7.6%	0.293	0.680	132.1%	0.531	0.771	45.2%
歯科	SC	R _{oop_area}	78.21	76.99	1.6%	0.106	0.164	54.7%	0.499	0.543	8.8%
歯科	全て	R _{ins}	30.58	32.61	-6.6%	0.415	0.270	-34.9%	0.723	0.678	-6.2%
歯科	全て	R _{oop}	76.04	68.08	10.5%	0.041	0.095	131.7%	0.566	0.571	0.9%
歯科	全て	R _{ins_area}	27.93	27.76	0.6%	0.243	0.257	5.8%	0.482	0.695	44.2%
歯科	全て	R _{oop_area}	71.86	80.4	-11.9%	-0.086	-0.153	-77.9%	0.419	-0.040	-109.5%
全診療科	SC	R _{ins}	46.82	51.17	-9.3%	0.029	-0.023	-179.3%	0.338	0.295	-12.7%
全診療科	SC	R _{oop}	109.95	99.04	9.9%	0.148	0.324	118.9%	0.616	0.725	17.7%
全診療科	SC	R _{ins_area}	49.49	43.03	13.1%	-0.065	0.051	178.5%	0.120	0.254	111.7%
全診療科	SC	R _{oop_area}	94.27	103.36	-9.6%	0.116	0.180	55.2%	0.665	0.662	-0.5%
全診療科	全て	R _{ins}	48.82	40.09	17.9%	0.022	0.430	1854.5%	0.390	0.661	69.5%
全診療科	全て	R _{oop}	102.4	80.54	21.3%	-0.096	0.167	274.0%	0.533	0.682	28.0%
全診療科	全て	R _{ins_area}	47.52	42.02	11.6%	-0.063	0.106	268.3%	0.210	0.460	119.0%
全診療科	全て	R _{oop_area}	114.48	92.95	18.8%	-0.207	0.215	203.9%	0.074	0.678	816.2%
平均			64.01	59.86	6.0%	0.087	0.231	198.2%	0.461	0.580	75.3%

ーパラメータ探索範囲は、カーネル：線形・RBF・多項式、正則化パラメータ：0.001～1000、不感帯幅：0.001～1.0、Gamma：0.00001～10.0 で、ベイズ最適化により探索を行う。

評価指標としては、売上予測誤差を測る際に重要なスケール非依存性を持つ対称平均絶対パーセント誤差 (sMAPE) を採用した。また、それ以外に決定係数 (R²)、Spearman の順位相関係数 (Rank Corr.) を算出して条件ごとの性能比較を行う。

2. 売上予測結果

表 1 は衛星画像由来データあり/なしで構築したモデルによる売上予測の結果である。衛星画像由来データなし→ありの比較として、全体平均では、sMAPE が 4.2 ポイント改善 (64.01%→59.86%)、R²が 0.144 改善 (0.087→0.231)、Spearman の順位相関係数が 0.119 改善 (0.461→0.580) した。診療科・立地・予測対象売上種類の組み合わせによる全 16 パターンのうち、sMAPE は 12 パターン (75.0%)、R²は 14 パターン (87.5%)、Spearman 相関係数は 12 パターン (75.0%) で改善を示した。

特に「全診療科×全立地×R_{ins} (保険診療売上)」で R²が 0.408 改善 (0.022→0.430)、「全

診療科×全立地× $R_{\text{oop_area}}$ (面積当たり自費診療売上)」で Spearman の順位相関係数が 0.604 改善 (0.074→0.678) と顕著な効果を確認した。一方、「歯科×全立地× $R_{\text{oop_area}}$ (面積当たり自費診療売上)」では衛星画像なしの方が良好な結果を示し、条件により衛星画像の有効性が異なることが明らかになった。

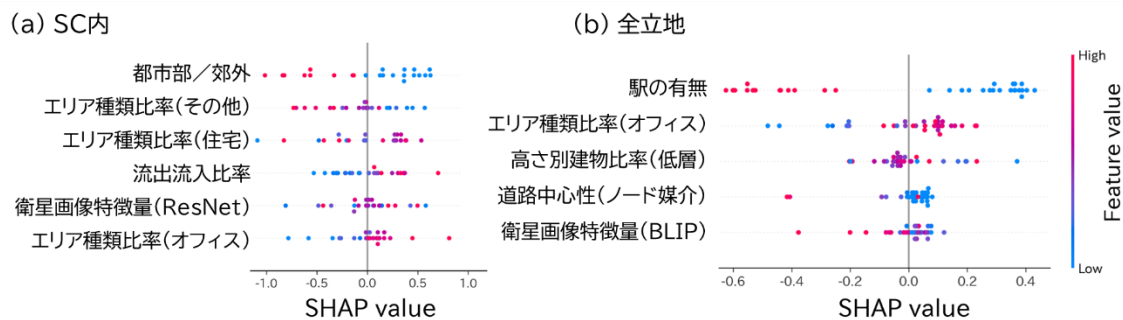


図 3 歯科の面積当たりの保険診療売上予測における SHAP 分析結果。(a)は SC 内、(b)は全立地のクリニックが対象




図 4 全診療科の面積当たりの自費診療売上予測における SHAP 分析結果。(a)は SC 内、(b)は全立地のクリニックが対象

これらの結果の総括としては、条件にもよるものの、衛星画像由来データは全体傾向として予測性能を改善することが分かった。

3. SHAP による特徴量の解釈

SHAP 分析により売上に影響する要因について分析した。図 3, 4 は歯科／全診療科の面積当たり保険／自費診療売上に対する SHAP 値である。(a)は SC 内、(b)は全立地の結果を示す。図 3(a)より、SC 内歯科では「都市部/郊外」が最も強い影響を示し、郊外型 SC 内クリニックの面積当たり売上が高い。次いで「エリア種別比率 (その他)」が重要で、複合的地域特性を持つ場所で高売上を示した。「流出流入比率」が高いエリアほど面積当たり売上が高く、朝夕の通勤・通学時間帯での利用需要を効果的に取り込めることを示唆している。図 3(b)では「駅の有無」が重要で、駅なしの立地で面積当たり売上が高い。SC 内以外に立地する歯科クリニックを含めると、駅から遠い方が有利に働く傾向がある。「エリア種別比率 (オフィス)」は正の影響を示し、オフィスエリアでの高売上を示唆している。

全診療科の面積当たりの自費診療売上を示す図 4(a)では、SC 内立地のクリニックで「流

出流入比率」と「市区町村中心性（次数）」が売上に正の影響を示した。これは、地域間の人の移動が活発な地域ほど SC 内クリニックの売上が高い傾向を示す。一方、図 4(b)の「SC フラグ」は負の影響を示し、SC 内に立地するクリニックは自費診療売上が低下する傾向にあった。

V. 考察

本研究の結果は、マルチモーダル地理データ統合がヘルスケア施設の売上予測において有効であることを実証した。衛星画像解析から得られた地域特性（エリア種類比率など）が予測精度向上に大きく貢献した。LMM によって低コストに抽出した潜在的な地域情報が、売上予測という実用的な目的で明確な貢献を示したことは、ヘルスケア施設のみならず商業施設全般の立地戦略に実践的示唆を提供する。

次に、ヘルスケア施設売上の立地特性分析の側面について考察する。SHAP により、クリニックの条件や立地タイプによって売上傾向が大きく変わることが分かった。例えば、図 3(a)の「歯科×SC 内のみ×面積当たりの保険診療売上」では日中に別市区町村へ出ていく人が多いエリアほど面積当たりの売上が高い傾向が判明した。これは、朝夕の通勤・通学時間帯についでに立ち寄る需要を効果的に取り込んでいる可能性がある。一方、図 4(b)で示される「全診療科×全立地×面積当たりの自費診療売上」では SC フラグが強い負の影響を示し、ショッピングセンターに出店しているクリニックほど自費診療売上が低くなる傾向が明らかになった。これは、自費診療を求める顧客が、プライバシーを重視し、独立した施設に出店するクリニックを好んでいる可能性がある。このように、LMM による多種データを抽出し、かつ探索的にデータ分析できる提案手法によって、ヘルスケア施設のような小規模データしか存在しない領域でも消費者行動を推定できることが分かった。

VI. まとめ

本研究は、マルチモーダル地理データ統合によるヘルスケア施設の売上予測手法を提案し、その有効性を実証した。104 種類の特徴量から多段階選定プロセスを経て最適な組み合わせを特定し、衛星画像統合により 16 パターンの売上予測タスクで sMAPE の全体平均が 4.2 ポイント改善した。LMM により抽出した地域特性が、従来手法では捉えきれなかった特徴を効果的に定量化し、予測精度向上に貢献した。提案手法は低コストで広範な地域特性を考慮でき、データドリブンな立地戦略決定を支援する汎用的な手法である。また、SHAP 分析により、立地や診療科によって売上に左右する要因が異なることを特定し、エビデンスに基づく立地戦略の指針を提示した。

謝辞

本研究を進めるにあたり、エムディー株式会社の皆様に多大なるご協力を賜りました。心より御礼申し上げます。

引用文献

- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An image is worth 16x16 words: Transformers for image recognition at scale. In **International Conference on Learning Representations (ICLR)**.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In **Proceedings of the IEEE conference on computer vision and pattern recognition**, 770-778.
- Jean, N., Burke, M., Xie, M., Davis, W. M., Lobell, D. B., & Ermon, S. (2016). Combining satellite imagery and machine learning to predict poverty. **Science**, 353(6301), 790-794.
- Li, J., Li, D., Xiong, C., & Hoi, S. (2022). Blip: Bootstrapping language-image pre-training for unified vision-language understanding and generation. In **International conference on machine learning (ICML)**, 12888-12900.
- Lim, B., Arik, S. O., Loeff, N., & Pfister, T. (2021). Temporal fusion transformers for interpretable multi-horizon forecasting. **International Journal of Forecasting**, 37(4), 1748-1764.
- Liu, X., & Ichise, R. (2017). Food sales prediction with meteorological data—A case study of a Japanese chain supermarket. In **Proceedings of Data Mining and Big Data**, 93-104.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. In **Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS)**, 4768-4777.
- Okengwu, U. A., Memmert, D., Rein, R., & Osuigbo, E. N. (2022). Predictive hospital site selection model using machine learning techniques. **Scientia Africana**, 21(1), 159-174.
- OpenAI. (2023). GPT-4 Technical Report. **arXiv preprint arXiv:2303.08774**.
- Park, Y. T., Kim, D., Jeon, J. S., & Kim, K. G. (2024). Predictors of medical and dental clinic closure by machine learning methods: Cross-sectional study using empirical data. **Journal of Medical Internet Research**, 26, e46608.
- Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., ... & others. (2021). Learning transferable visual models from natural language supervision. In **International conference on machine learning (ICML)**, 8748-8763.
- Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T. (2020). DeepAR: Probabilistic forecasting with autoregressive recurrent networks. **International Journal of Forecasting**, 36(3), 1181-1191.

Yeh, C., Perez, A., Driscoll, A., Azzari, G., Tang, Z., Lobell, D., ... & Burke, M. (2020). Using publicly available satellite imagery and deep learning to understand economic well-being in Africa. **Nature communications**, 11(1), 2583.

総務省統計局. (2022). 令和 2 年国勢調査結果, <https://www.stat.go.jp/data/kokusei/2020/>

荒川周造, 諏訪博彦, 小川祐樹, 荒川豊, 安本慶一, & 太田敏澄. (2018). 暗黙知に基づく飲食店向け不動産賃料推定モデルの提案. **情報処理学会論文誌**, 59(1), 33-42.

丹生晃隆, & 松本. (2008). 小規模店舗売上予測・立地判定システムの開発－統計データ解析し高い精度の方程式－. **産学官連携ジャーナル**, 4(2), 4-5.