

組合せ最適化

厳密解法とヒューリスティクスによる
複雑な意思決定の最適化

組み合わせ最適化とは「変数が離散的な値をとる最適化問題」

- 目的：有限な選択肢から、特定の制約を満たしつつ最も良い組み合わせを選ぶ
- 特徴：連続値ではなく、離散値 (0か1、整数など) を決定変数とする
- 具体例：配送ルート計画 (VRP)、施設配置、ダイヤ編成

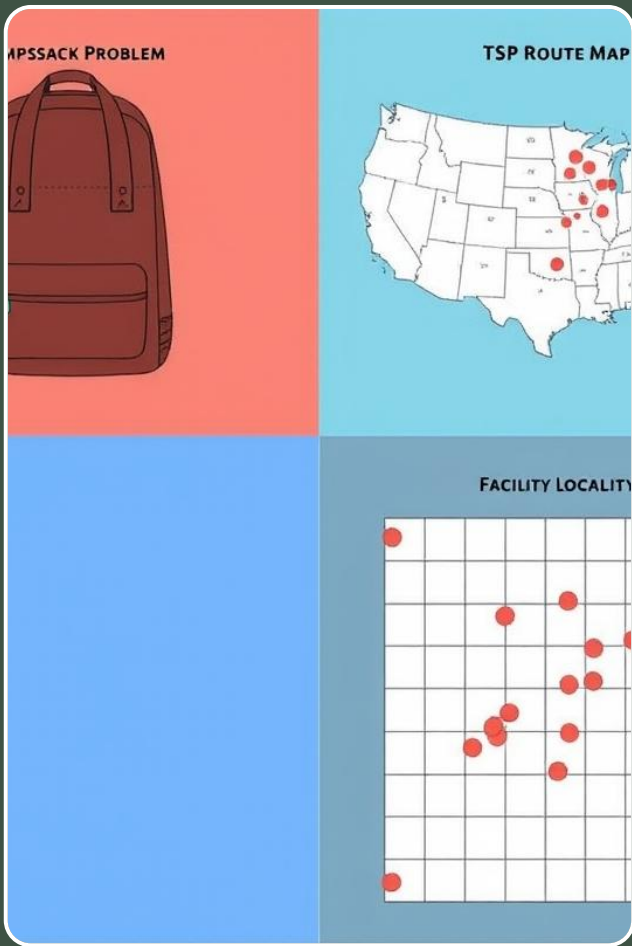
最適化問題の基本形：

$$\min f(x) \quad \text{subject to} \quad x \in X, x_i \in \{0, 1\}$$

(x_i は「選ぶ/選ばない」などの離散的な意思決定)

代表的な組合 せ最適化問題

- ナップサック問題: 容量制限内で価値最大化
($\sum w_i x_i \leq W, \max \sum v_i x_i$)
- 巡回セールスマン問題 (TSP): 全都市を1回ずつ巡り
最短経路を求める ($\min \sum c_{ij} x_{ij}$)
- 施設配置問題: 顧客への距離最小化で施設数を固定
(p-medianモデル)



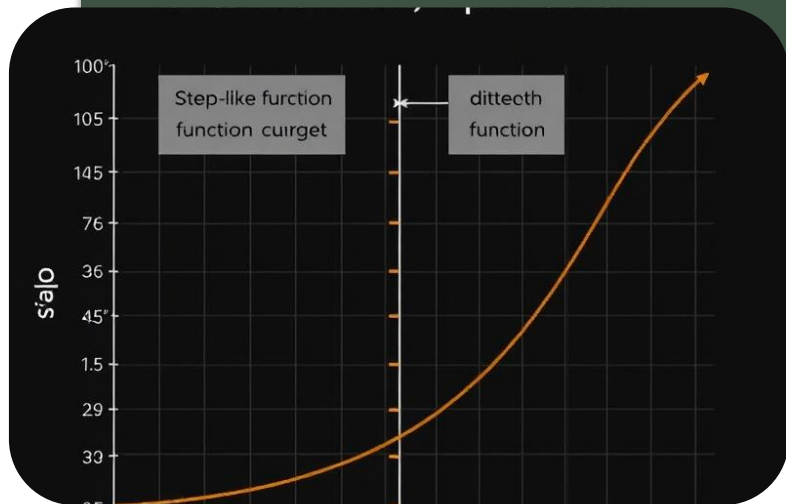
整数計画と0-1 計画の基礎

整数計画問題(IP)は、変数が**整数値のみ**を取る最適化問題。

0-1計画問題は、変数が0または1しか取れない特殊なIPで、選択・非選択を表す。

「局所最適解」が「大域的最適解」とは限らない

離散的な決定が必要な場面で活用
例) 現実の設備配置やスケジューリング等



組合せ爆発

- 直面する壁：問題サイズが大きくなると、候補数が指数関数的に増大する
- NP困難性：すべての候補を計算機で調べる（全列挙）ことは実質不可能
- 戦略の必要性：「賢く探索する」アルゴリズムが不可欠
- 巡回セールスマン問題（TSP）の候補数： $O(n!)$ （都市数 $n = 20$ で約243京通り（天文学的数字）に到達）

厳密解法と近似解法

- 厳密解法：
数学的に**最適解を保証**する手法。
計算時間がかかる場合がある
小規模問題に適用可能
- 近似解法：
十分良い解を**短時間で得る**手法。
最適保証はできない。
大規模問題に適用




厳密解法①：分枝限定法（Branch and Bound）

- 方針：探索空間を分割（分枝）し、不要な部分を理論的に切り捨てる（限定）
- 仕組み：緩和問題から得た「下界」と、暫定解の「上界」を比較して枝刈り
- メリット：全列挙を避けつつ、最適解を完全に保証できる

枝刈り（Pruning）の条件：

$$Z_{\text{lower_bound}} \geq Z_{\text{upper_bound}} \Rightarrow \text{探索不要}$$

（部分問題の理論上の最小値が、すでに見つけた暫定解より悪ければ、その先は探さない）




厳密解法②：切除平面法（Cutting Plane Method）

- 方針：整数条件を一時的に無視して解き、後から不要な小数を排除する
- 仕組み：整数解は残しつつ、小数解だけを切り落とす「制約（カット）」を追加
- メリット：線形計画ソルバーの高速な計算力を活用できる

代表的なカット（TSPの部分巡回除去制約）：

$$\sum_{i \in S} \sum_{j \in S} x_{ij} \leq |S| - 1 \quad \forall S \subset V, |S| \geq 2$$

（意味をなさない「小さなループ」を排除する
数式を後から追加する）



厳密解法の意義と限界

解空間を体系的に探索し、理論的に「最適解」であることを証明可能。

しかし、多くの組合せ最適化問題はNP困難であり、変数が増えると計算時間が現実的な範囲を超えてしまう。

そのため、大規模な現実問題では、最適解に近い「近似解」を迅速に見つける近似解法が不可欠。

ヒューリスティクス：最適性よりも実用的な速度を

方針：最適解の保証を捨て、「十分に良い解」を高速に探す

- 近傍探索 (Local Search)：初期解から少しずつ解を変化させ、改善を繰り返す
- 初期解の設定：単純構成法と構成ヒューリスティクス法

近傍探索における局所最適解の定義：

$$f(x^*) \leq f(x) \quad \forall x \in N(x^*)$$

(近傍 $N(x^*)$ の中のどの解よりも、現在の解 x^* の方が優れている状態)



近傍探索が陥る「局所最適解の罠」

- 課題：目の前の改善だけを追いかけると、本物の山頂に辿り着けない
- 局所最適解：その周辺エリアの中では一番良いが、全体での最高峰ではない解
- 限界：単純な近傍探索は、ここで探索がストップしてしまう

大域的最適解 (Global Optimum) との関係：

$$f(x_{\text{global}}) \leq f(x_{\text{local}})$$

(局所最適解は、必ずしも真の最適解とは一致しない)



罨から脱出する「メタヒューリスティクス」

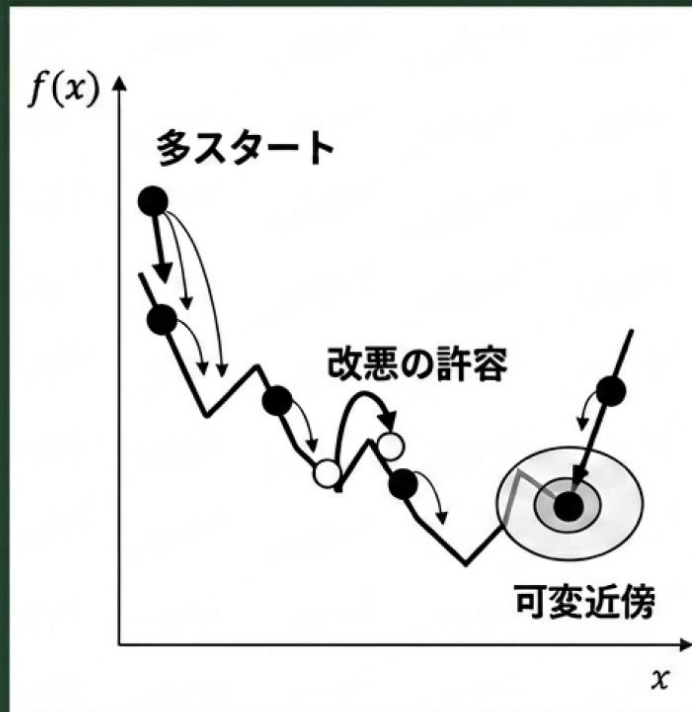
メタヒューリスティクス：局所探索を制御し、罨を抜け出すための上位戦略

- 手法1：多スタート法 → 初期解を何度も変えて登り直す
- 手法2：改悪の許容（焼きなまし法など） → 確率的に一時的な「下り坂」を許す

$$P(\text{accept}) = \exp\left(\frac{f(x_{\text{current}}) - f(x_{\text{new}})}{T}\right)$$

(温度 T が高い初期は、改悪解でも受け入れて広く探索する)

- 手法3：可変近傍探索 → 探す範囲（近傍）の大きさを動的に変える



解法戦略の使い分け（マトリクス）

Trade-off: Optimality \Leftrightarrow Computational Time

	厳密解法 (Exact Methods)	ヒューリスティクス (Heuristics)
最適性の保証	完全保証（真の最適解）	保証なし（局所最適の可能性）
計算時間	膨大（問題サイズにより指数的）	高速（実用的な時間で完了）
適用シーン	小～中規模、インフラ設計、ベンチマーク	大規模、日々の運用、リアルタイム配車
代表的手法	分枝限定法、切除平面法	局所探索、メタヒューリスティクス



Problems requiring the selection of specific combinations from a finite set.

Examples include Shortest Path, Traveling Salesman Problem (TSP), and Delivery Routing.

What is Combinatorial Optimization?

自動運転オンデマンド交通の最適サービス設計

高尾駅周辺を対象に、自動運転オンデマンド交通の「対象領域・拠点配置・車両台数」の最適化問題を定義する。

CONTEXT & SCOPE

【目的】

- ・ 端末交通としての自動運転オンデマンド交通の最適なサービス設計の分析

【対象領域】

- ・ 高尾駅周辺3km圏内

3つの主要課題

【対象ゾーン】 どのエリアをサービス範囲に含めるか？ >



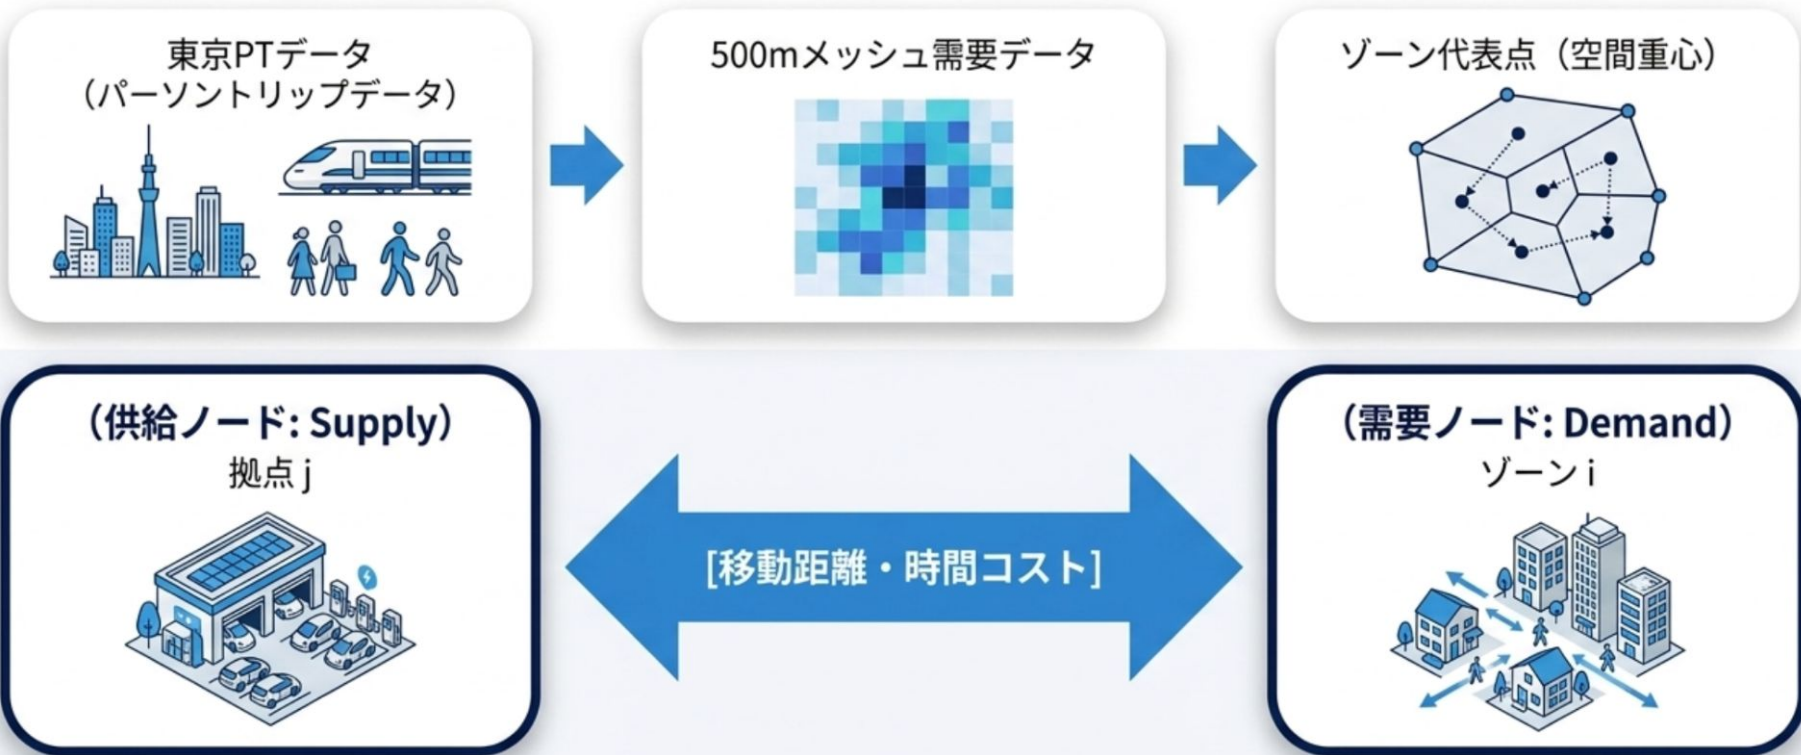
【拠点配置】 どこに車両拠点を配置するか？ >



【フリート規模】 どの程度の車両台数で成立するか？ >

データ構造とネットワークモデル

現実の需要と空間を、ゾーン（需要）と拠点（供給）のネットワークとしてモデル化する。



- 拠点 (Hub) : 車両の待機・発着地点
- ゾーン (Zone) : 発生する移動需要の集約点
- コスト定義: 拠点とゾーン間の移動距離・時間をネットワーク近似により算出

定式化 (1) 変数定義と目的関数

総サービス時間を最小化するため、拠点選択とゾーン割当の0-1整数計画問題として定式化する。

[決定変数 (Decision Variables)]

$x_j \in \{0,1\}$: 拠点 j を選択するか

$y_{ij} \in \{0,1\}$: ゾーン i を拠点 j が担当するか

[目的関数 (Objective Function)]

総サービス時間の最小化:

$$\min \sum_i \sum_j (demand_i \times service_time_{ij} \times y_{ij})$$

※ $service_time_{ij}$ = 往復時間 + バッファ + 駅接続コスト

[システム制約 (System Constraint)]

(1) カバー率制約: 全体の需要に対して一定割合 (α) 以上をカバーする

$$\sum_i covered_demand_i \geq \alpha \times total_demand$$

定式化 (2) 物理・運用上の制約条件

各ゾーンへの単一拠点割当に加え、近接制約と容量制約によって現実的な配車を担保する。

配置・割当制約 (Location & Assignment)

(3) 拠点数制約：選択する全拠点数は P 個に固定する。

$$\sum_j x_j = P$$

(4) 割当制約：各ゾーンは選ばれた1つの拠点にのみ割り当てる。（※論理的排他制約）

運用制約 (Operational Bounds)

(5) 近接制約 **[本研究の新規性]**：ゾーン i は、距離が近い上位 k 個の拠点（集合 $N_k(i)$ ）にのみ割当可能とする。

$$y_{ij} = 0 \quad (\forall i, \forall j \notin N_k(i))$$

(6) 容量制約：各拠点のサービス時間合計は、保有する車両フリートの総容量を超えない。

$$\sum_i \text{service_time}_{ij} \times y_{ij} \leq \text{fleet} \times \text{capacity} \quad (\forall j)$$

最適化アプローチ

SciPyを用いたMILPソルバーにより、全候補の組み合わせから厳密最適解を探索する。



[アプローチの特徴]

- 問題クラス：0-1混合整数線形計画問題（MILP）
- 探索方針：全候補拠点の組み合わせを網羅的に評価し、大域的最適解を保証
- 実装環境：Python（SciPyモジュール）環境による最適化モデルの構築と実行

評価指標とパラメータ設定

ネットワーク距離から推定したサービス時間と、普及率を考慮した有効需要を用いて解を評価する。

1. ネットワーク距離推定 (Spatial Metrics)

- `distance_km`: 拠点～ゾーン間の空間距離
- `travel_time_min`: ネットワーク構造から走行時間を換算

2. サービスコスト定義 (Cost Metrics)

- `service_time`: 往復時間 + バッファ + 駅接続コスト (総所要時間)

3. 需要モデル (Demand Model)

- `effective_demand`: 潜在需要 \times `adoption_rate` (普及率 20%と仮定)


最適解の結果とパフォーマンス

高尾駅を含む3拠点での最適運用において、容量制約が上限に達しシステム稼働率が最大化された。

[設定条件 (Input Parameters)]

- 拠点数 $P = 3$
- 近接上限 $k = 8$
- カバー率制約 $\alpha \geq 0.5$
- 公平性制約 $\beta \geq 0.3$

[最適配置構造 (Optimal Hub Topology)]



[主要KPI (Performance Dashboard)]

- カバー率 (Coverage) : 約 0.50 (制約下限で均衡)
- 総サービス時間 : 約 3600 分

稼働率 (Capacity Utilization) :

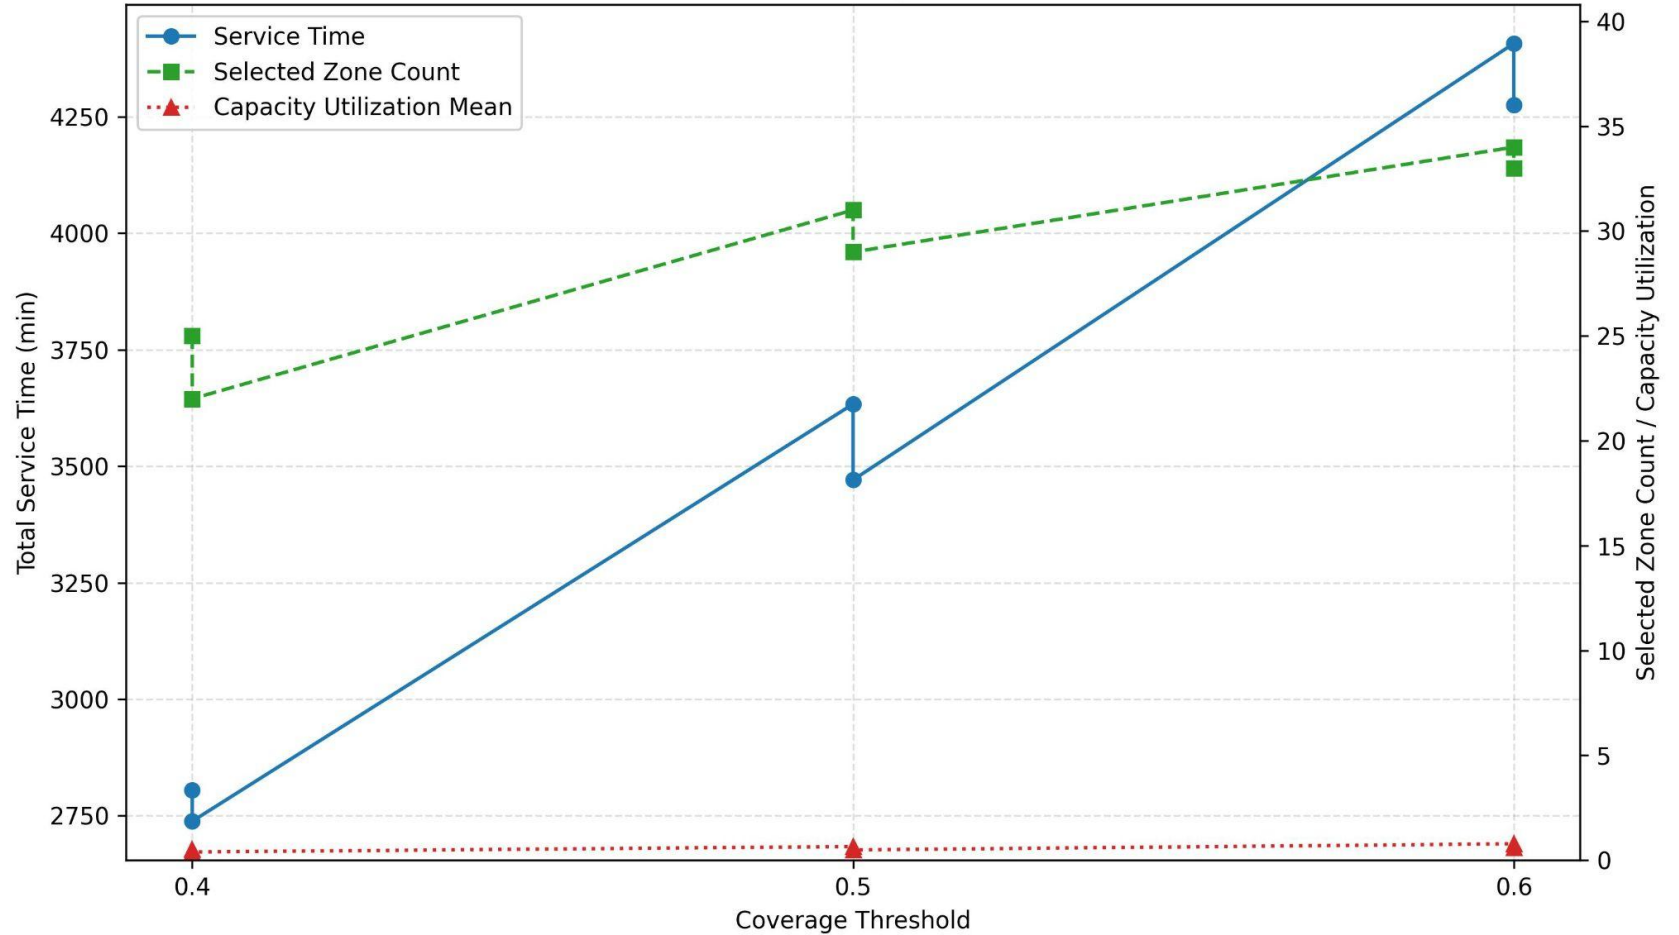
(容量制約が強くバインディング)

約 1.0


Summary of Key Cases

case_name	P	coverage_threshold	total_service_time_mi	coverage_ratio	capacity_utilization_mean
P3_k8	3	0.5	3633.2	0.5	0.65
cov40_k8	3	0.4	2805.24	0.4	0.52
cov50_k8	3	0.5	3633.2	0.5	0.65
cov60_k8	3	0.6	4407.11	0.6	0.78
beta00_k8	3	0.5	3633.2	0.5	0.65
beta05_k8	3	0.5	3633.2	0.5	0.65
beta10_k8	3	0.5	3633.2	0.5	0.65


Trade-off between Coverage and Service Time



Effect of Number of Hubs (P) on Service Performance



Effect of Fleet Size on Feasibility and Performance



考察：空間構造の違いと問題の支配的要因

サービス成立性は容量制約とカバー率のトレードオフに依存し、都市と地方で支配的な制約が異なる。

【最適化結果に対する考察】

- 拠点数を増やしても、総サービス時間の劇的な効率改善は見られない。
- フリート（車両台数）と容量制約が、システム全体の限界を決定づけている。

都市部（例: 高尾）

- 需要特性: 需要密度が高い
- 支配的制約: 「容量制約」がバインディングする
- 問題構造: いかに限られた車両リソースで溢れる需要を捌くか (Fleet Optimization)

地方部（例: 伊方）

- 需要特性: 需要が広域に分散
- 支配的制約: 「拠点配置（距離）」がバインディングする
- 問題構造: いかに関遠方の需要を効率的にカバーする拠点網を敷くか (Topology Optimization)

結論：地域の空間構造に応じて、オンデマンド交通の最適化モデルは力点が根底から変化する。

今後の展望

① 端末交通としてのNW表現

→ 実際の道路NWの反映、経路計算や混雑制約の導入など

② 拠点割当の厳密化

→ 各ゾーンを最寄り拠点に限定($k=1$)

③ 拠点配置の現実化

→ 駅・学校・公共施設を候補とした現実の立地条件の反映

④ 地方(伊方)への展開

→ 需要密度が分散、空間構造の制約が支配的な土地への応用

LLM活用

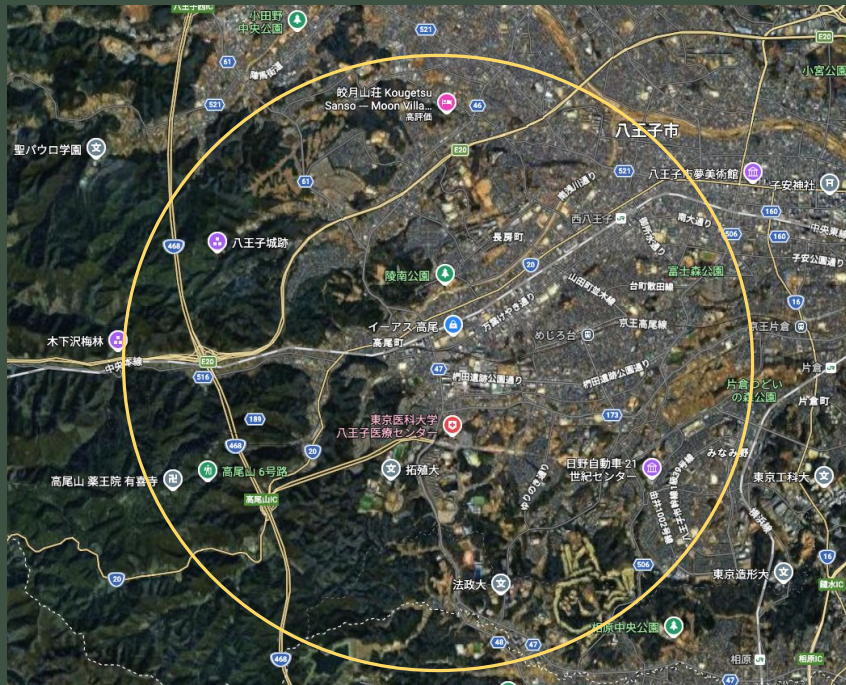
スライド生成を複数のLLMで行い、比較した。

- ①教科書説明→AI Slide(Google slide プラグイン)
- ②演習課題→NotebookLM

後者の方が出力の質は高いが、編集の柔軟性が低い
最適なツール・活用法を模索していきたい

(本資料は後ほど体裁を整えて再アップロードします)

対象地域とデータ構造



対象: 高尾駅周辺3km圏内

データ: 2019年度PT調査データと500mメッシュ需要データの統合

ネットワーク: ゾーン(需要)と拠点(供給)の
双方向接続