


情流が人流を駆動するとき



2017年9月12日(火)9:30~12:00
東大本郷 L会場(3号館2階 31号講義室)

株式会社デンソー
先端研究4部人間特性システム研究室
笹木 美樹男



はじめに

- 2020年以降の新モビリティの台頭と“利用”市場への大規模な流入
→ 人の時空間移動の価値観が大きく変化
- 「歩いて楽しい、マイカー、シェアカー、公共交通、自転車が共存できる快適な社会」の実現をめざす都市計画に注目
- 移動需要の原点となる“情流”と“環境価値”を提案→人流の円滑化手段を模索する

ドイツ

TTT(技術、才能、寛容)で国内413都市中第1位エアランゲン市
(10万人)に見る元祖コンパクトシティ (ミュンヘンは2位)

25%が外国にルーツ。人口流動が活力。都市連携。壁→街を変える鳥瞰的思考。
外国人・難民を積極的受け入れ・反人種差別
歩いて10分のメインストリートが賑う、文化的で落ち着いた雰囲気の小さな都市
社会的思考と文化/価値観/アイデンティティの2層構造
400年間最新であり続ける、時代に合った経済を生み出し、都市を発展
都市の中心市街地、要塞、大学町、高い求心力、文化フェスティバル
スポーツ、自転車交通、都市農園、企業戦略、余暇はボランティアに。産学官協力

フランス

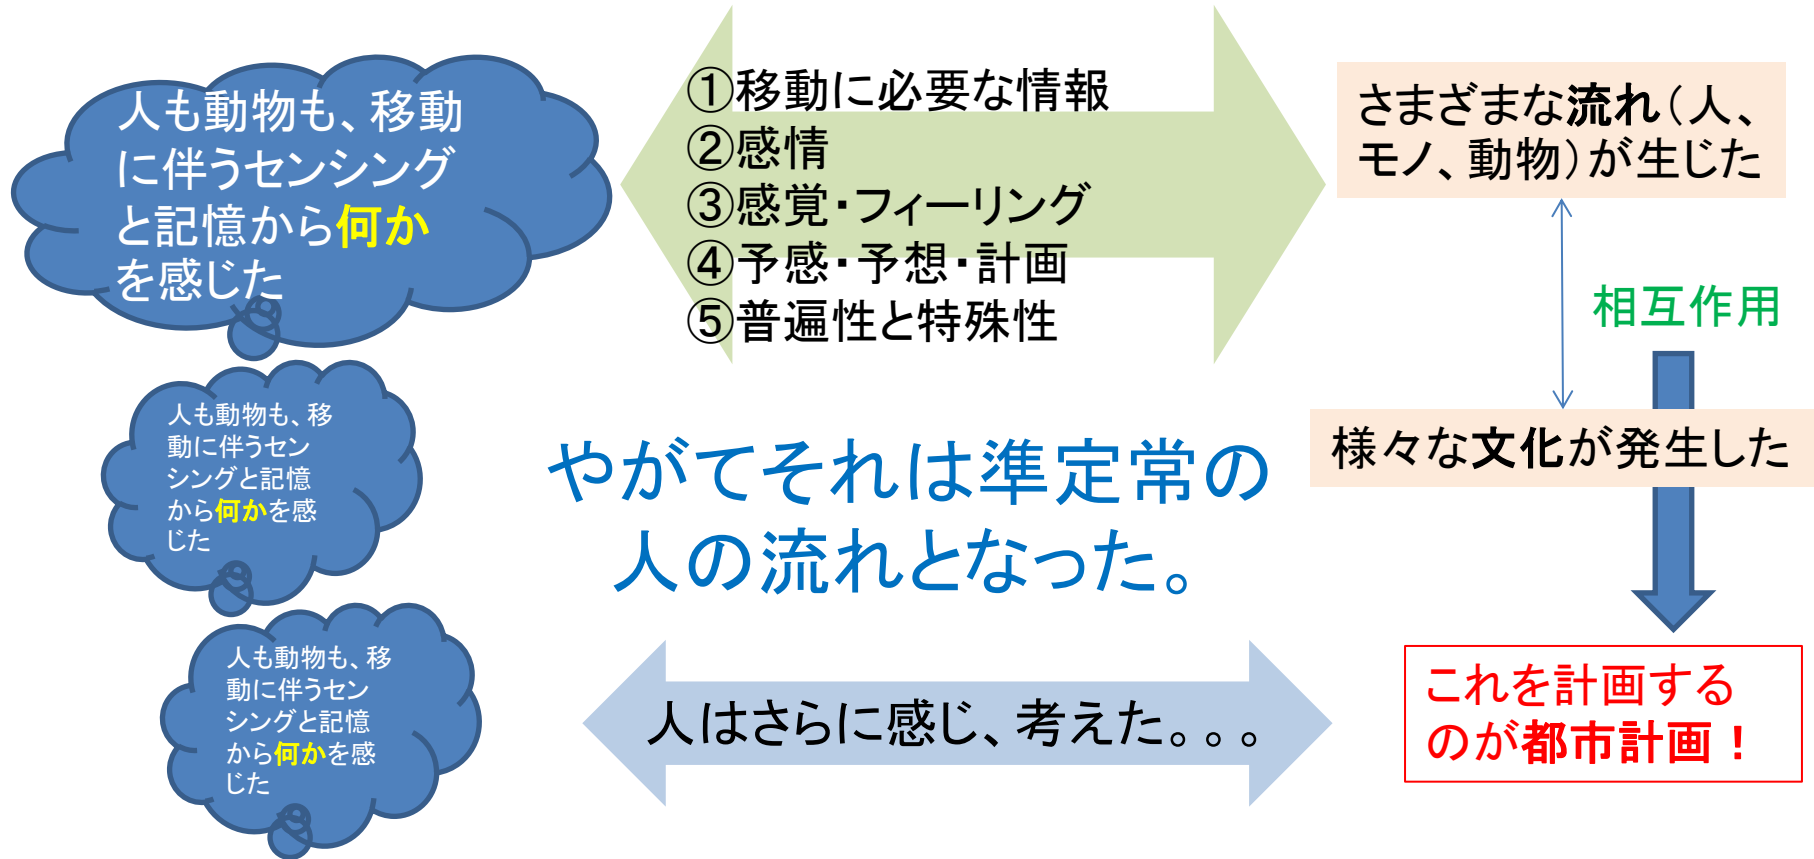
住みやすい街No.1:アンジェ市、ストラスブール市に見るコンパクトシティ

歩いて暮らせる町 歩行者安全対策
クルマと共存して利便性が増す公共交通、カーシェアリングの台頭

都市のクリエイティビティは人口規模に比例せず、人流に起因!?

まず、環境ありき


太古の昔より、人も動物も生きる糧を求めてさまよう。。。



動く前にまず、行きたい場所や環境を思い浮かべよう

人は環境に価値を見る

ただ生きるための移動から



もっと快適に

もっとxxに..

POI (Point Of Interest), Landmark



時空間移動経路の各点が有する多元的価値に基づくポテンシャルエネルギーEV



環境価値EV

- 実空間の時空間に対応したEV
- 仮想空間の時空間に対応したEV

仮説: 理想的な時空間移動とは

- 実空間の時空間移動が
- 仮想空間における**情流**の時空間移動にマッチする(一致ではない)ことに相当する



$$X = \sum_{t=t1}^{t2} EV_GET \{ trajectory (real_space, virtual_space), situation \}$$

そして、様々な情流が形成されていく

では、情流って具体的に何？

Information : ユーザの移動需要に関する情報

Emotion : ユーザの感情(特に調停時)

Feeling : ユーザの“漠然とした思い

←これに着目

$$F(t_n) = (F_{moving_demand}(t_n), F_{feeling}(t_n) \cdots, F_{emoton}(t_n))$$

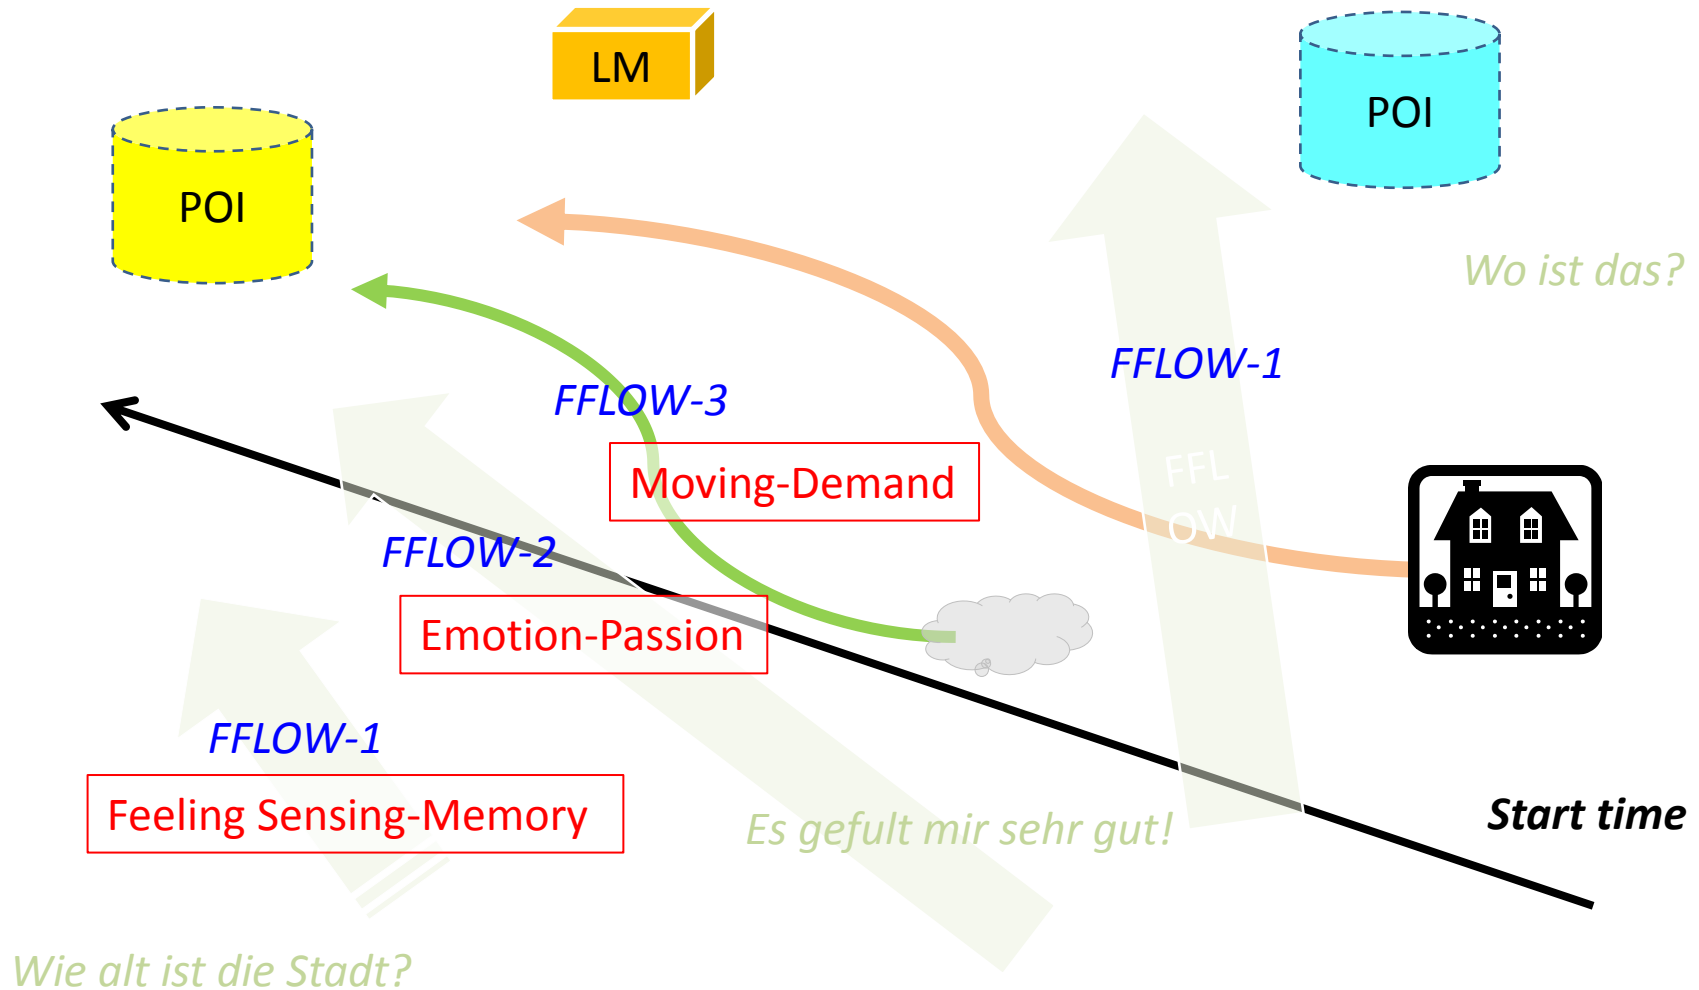
$$F(t_n) \cong F_{feeling}(t_n)$$

Virtualな環境価値(快適性ポテンシャル)の時系列を生成する

これが、Moverの理想的な移動状態を具象化する

情流の3段階

$$PFLOW(t, x) = FFLOW(t + \Delta U(t), x + \Delta V(x))$$



人流はその源、情流から予測できるのでは!?

情流はイメージで駆動される



鹿苑寺(金閣寺)



南禅寺



清水寺



伏見稲荷神社



情流はイメージで駆動される



仮説：情流は快適性を最大化する

では、快適性のポテンシャルとは？

100人 (Mover) の特徴と
100箇所 (LM) の特徴から
快適性を計算する

$$\dot{E} = \dot{U}_D \dot{U}_S^T = W(U_D, W_D) W(U_S, W_S)^T$$

where, $[W(A, B)]_{ij} = [A]_{ij} [B]_{ij}$

異なる時空間領域へのマッピングについて

人流の普遍性に起因する事例であり、これは情流に帰する。

Mover (移動者) の初期値にはLM (ランドマーク) の基本語彙に対応する共通のベクトルが仮定でき、入力の手間が大幅に削減できる。

```

.....:
// ●LM0: 高知城 <== 名城公園・ジョギングステーション <== グラバー園、ちゃんぽん、カステラ
UsrSA[0][0]=5; UsrSA[0][1]=5; UsrSA[0][2]=9; UsrSA[0][3]=8; UsrSA[0][8]=5;
UsrSA[0][10]=3; UsrSA[0][11]=9; UsrSA[0][12]=5; UsrSA[0][13]=2;
UsrSA[0][20]=10; UsrSA[0][21]=6; UsrSA[0][25]=7; UsrSA[0][28]=7;//★
// ●LM1: xxxxx <== 東山公園 <== 稲佐山展望台、トルコライス
UsrSA[1][1]=4; UsrSA[1][2]=1; UsrSA[1][3]=3; UsrSA[1][8]=8;
UsrSA[1][10]=3; UsrSA[1][11]=2; UsrSA[1][12]=3; UsrSA[1][13]=6;
.....:

```

今回、xxxxxには適当なLMが見つけれなかった。
これはターゲットとなる時空間領域の特殊性に起因する。

快適性をMoverから算出する

快適性：

$$\dot{E} = \dot{U}_D \dot{U}_S^T$$

Mover

// 0: 時間
 // 1: コスト
 // 2: 定員
 // 3: 近さ
 // 4: 趣味・景色・
 歴史・名所・旧跡
 // 5: 天候
 // 6: 嗜好性・買物
 // 7: 喫煙・飲酒
 // 8: 食事
 // 9: 遊具・スポー
 ツ・マリンリゾート

その他拡張
 100次元程度

.....

$$\dot{E} = \dot{U}_D \dot{U}_S^T = W(U_D, W_D) W(U_S, W_S)^T$$

$$E = U_D U_S^T$$

$$= \begin{bmatrix} \mathbf{u}_{D1} & \mathbf{u}_{S1} \\ \dots & \dots \\ \mathbf{u}_{Di} & \mathbf{u}_{Sk} \\ \dots & \dots \\ \mathbf{u}_{DI} & \mathbf{u}_{SK} \end{bmatrix}^T = \begin{bmatrix} \mathbf{u}_{D1} \\ \dots \\ \mathbf{u}_{Di} \\ \dots \\ \mathbf{u}_{DI} \end{bmatrix} \begin{bmatrix} \mathbf{u}_{S1}^T & \dots & \mathbf{u}_{Sk}^T & \dots & \mathbf{u}_{SK}^T \end{bmatrix} = \begin{bmatrix} \mathbf{u}_{D1} \mathbf{u}_{S1}^T & \dots & \mathbf{u}_{D1} \mathbf{u}_{Sk}^T & \dots & \mathbf{u}_{D1} \mathbf{u}_{SK}^T \\ \dots & \dots & \dots & \dots & \dots \\ \mathbf{u}_{Di} \mathbf{u}_{S1}^T & \dots & \mathbf{u}_{Di} \mathbf{u}_{Sk}^T & \dots & \mathbf{u}_{Di} \mathbf{u}_{SK}^T \\ \dots & \dots & \dots & \dots & \dots \\ \mathbf{u}_{DI} \mathbf{u}_{S1}^T & \dots & \mathbf{u}_{DI} \mathbf{u}_{Sk}^T & \dots & \mathbf{u}_{DI} \mathbf{u}_{SK}^T \end{bmatrix}$$

$$= \begin{bmatrix} E_{11} & \dots & E_{1k} & \dots & E_{1K} \\ \dots & \dots & \dots & \dots & \dots \\ E_{i1} & \dots & E_{ik} & \dots & E_{iK} \\ \dots & \dots & \dots & \dots & \dots \\ E_{I1} & \dots & E_{Ik} & \dots & E_{IK} \end{bmatrix}$$

ダイナミックなユーザプロフィールと、
 スタティックなユーザプロフィールの
 内積相関を取る。各プロフィールには
 ユーザモデルの荷重をかけておく。

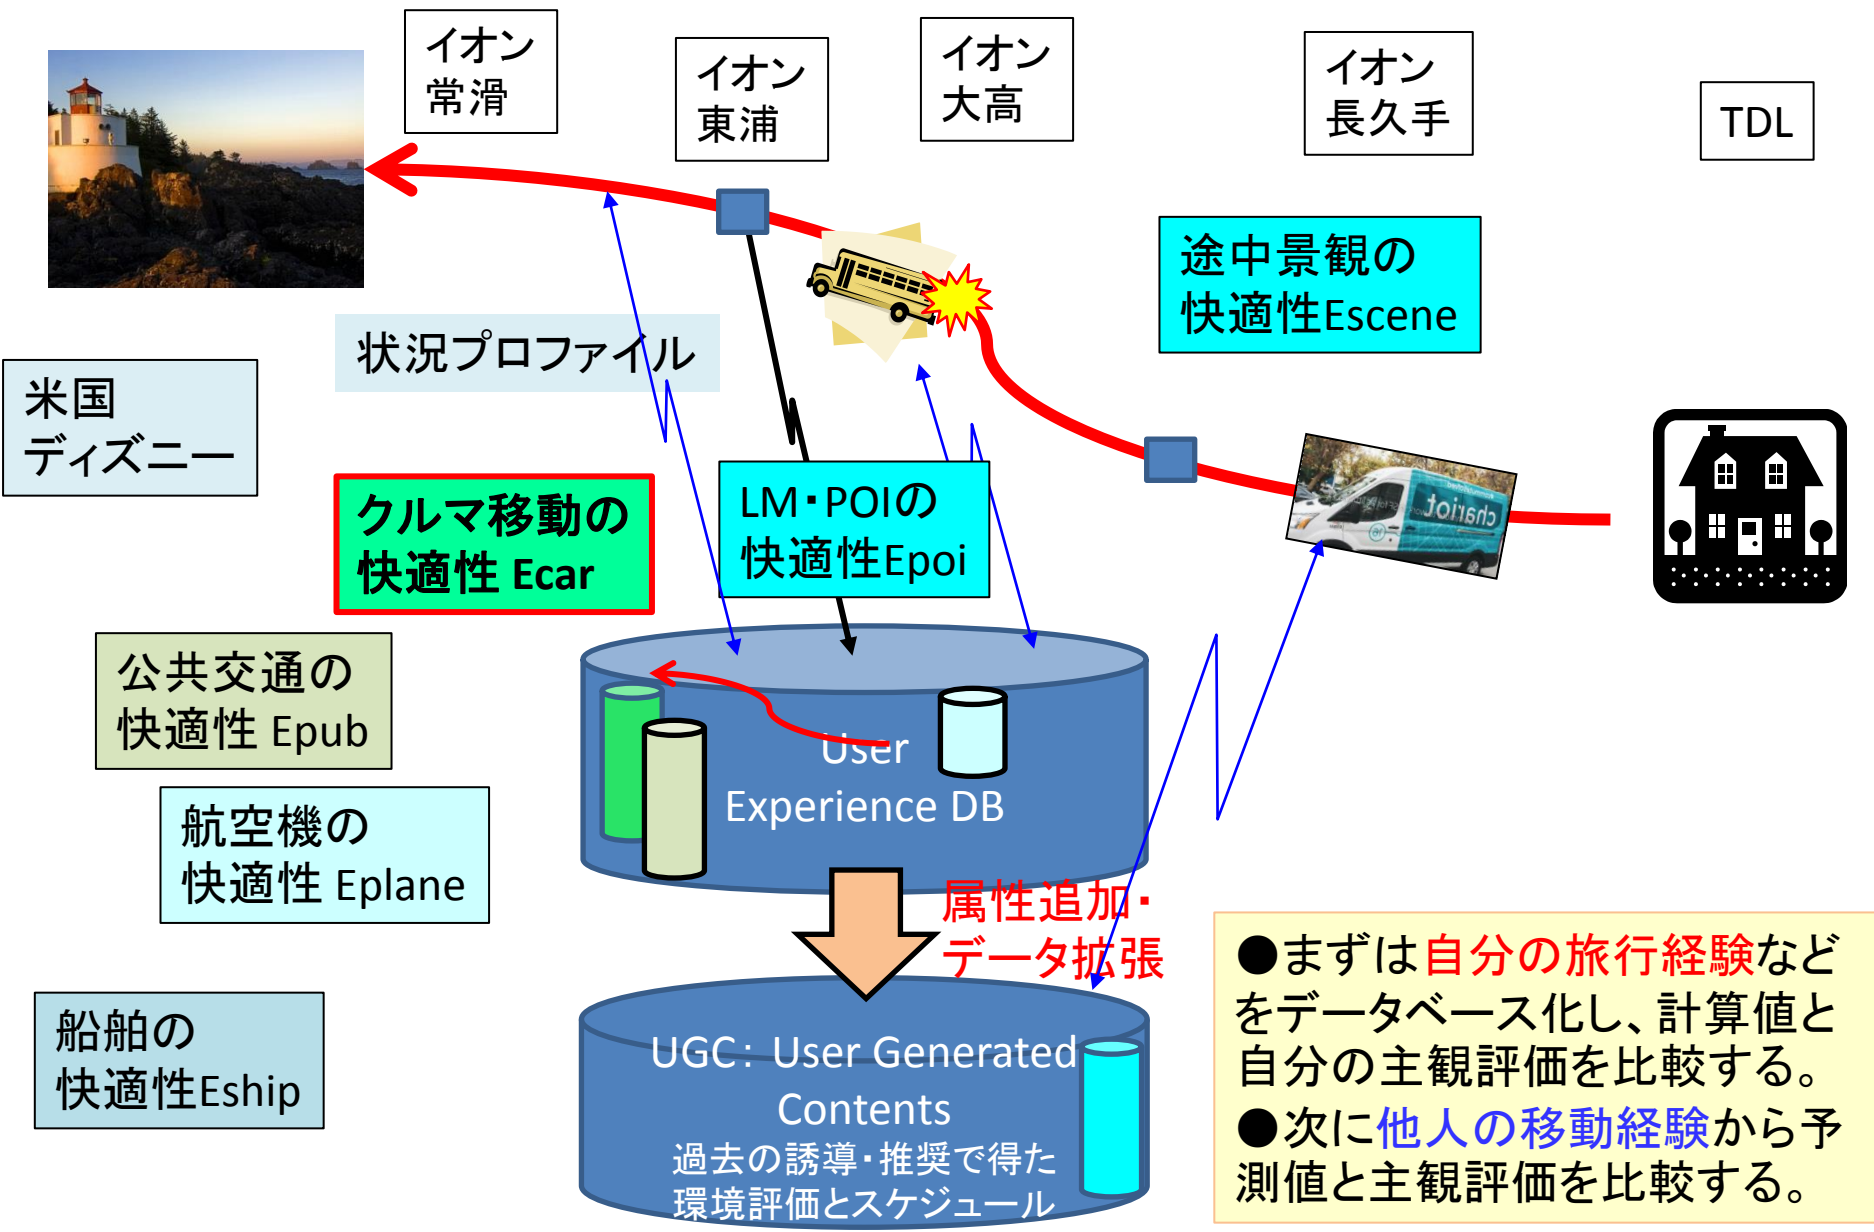
where,

$\mathbf{u}_{Ai} = (u_{A(i,1)}, u_{A(i,2)}, \dots, u_{A(i,j)}, \dots, u_{A(i,J)})$: Mover Vector Form ($A = D, S$)

$E_{ik} = \mathbf{u}_{Di} \mathbf{u}_{Sk}^T$: Comfort Potential Energy of i th user for k th landmark.

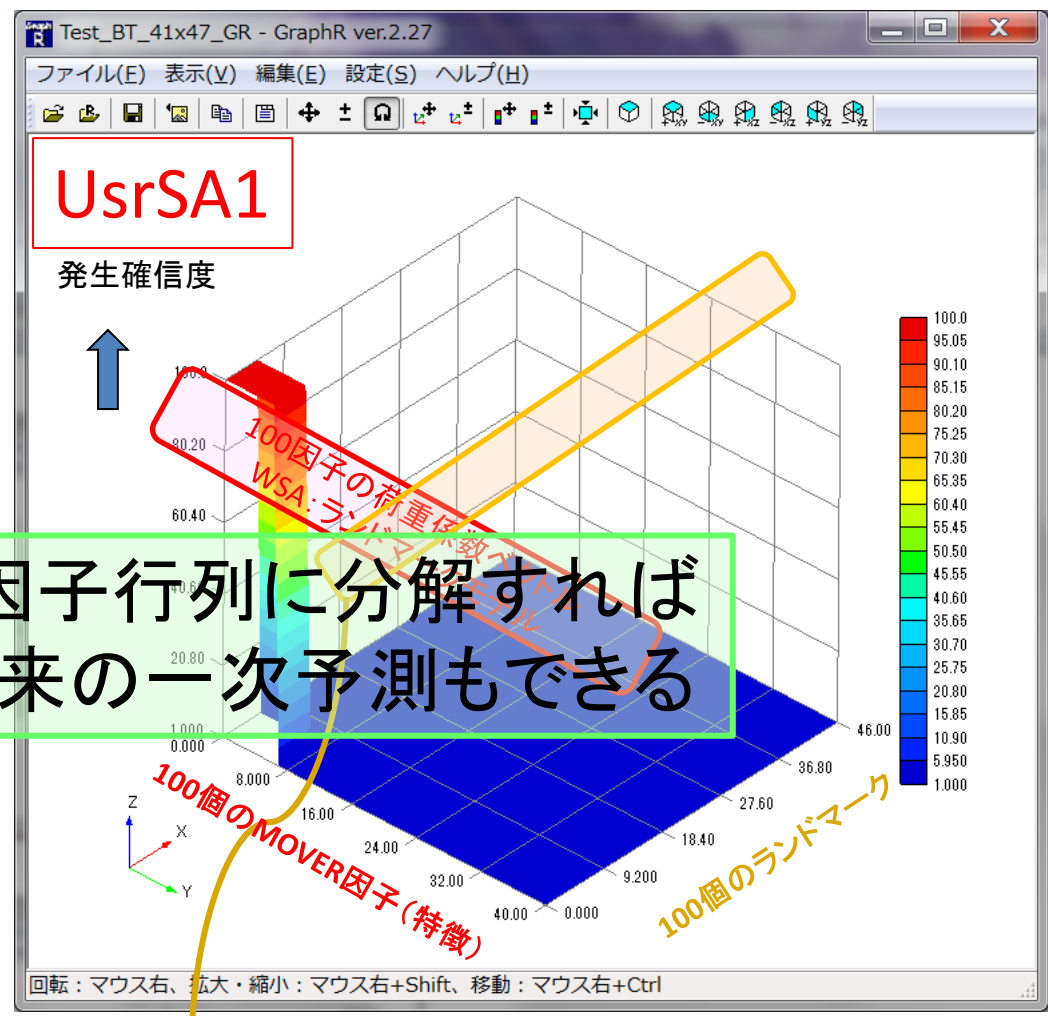
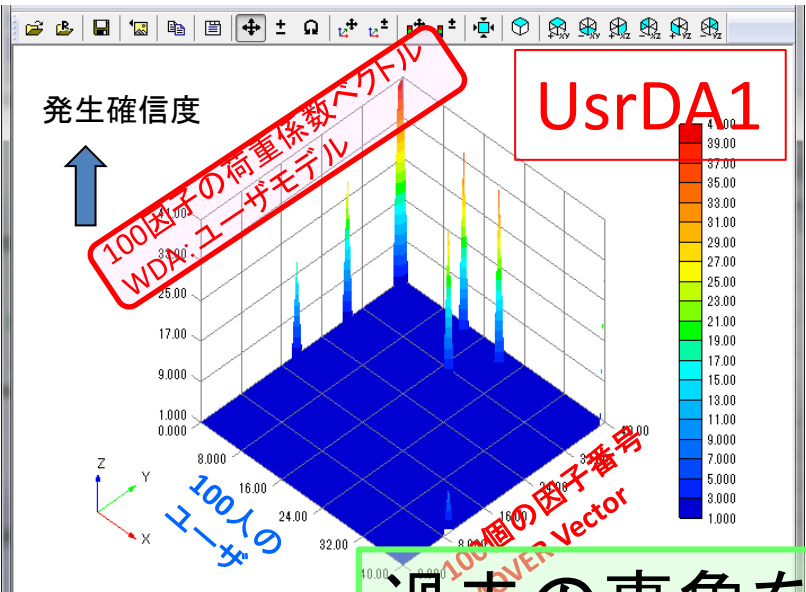
I, J, K means the number of users, the number of dimensions of Mover Vector, and the number of target landmarks, respectively.

快適性をユーザー体験DBで予測する

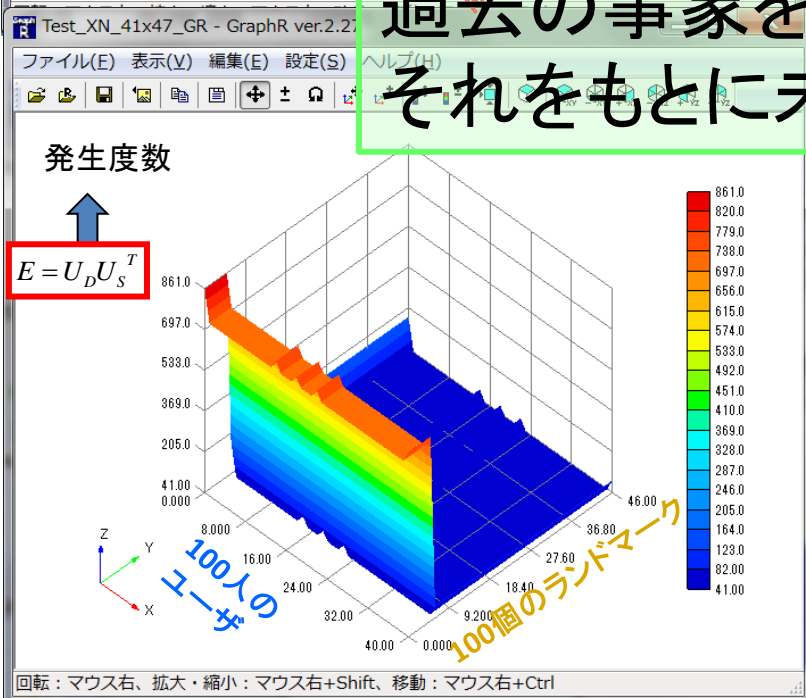


- まずは**自分の旅行経験**などをデータベース化し、計算値と自分の主観評価を比較する。
- 次に**他人の移動経験**から予測値と主観評価を比較する。

NMFでMOVER～快適性を予測する



過去の事象を因子行列に分解すれば
それをもとに未来の一次予測もできる




R番目の因子に対応する
100次元の事象パターン(ランドマーク)ベクトル

$$\dot{E} = \dot{U}_D \dot{U}_S^T = W(U_D, W_D) W(U_S, W_S)^T$$


例えば昨年のある事象の予測

NMF synthesis of Aug.1(Mon) to 27(Sat)




特定の評価基準ではあるが、
92.4%の予測率を達成！


Predicted values of Aug.28(Sun)



Real achievements of Aug.1(Mon) to Aug.27(Sat)



Real achievements of Aug.28(Sun)



To predict EV on Aug.28(Sun) from the past results of Aug.1(Mon) to Aug.27(Sat)

実験システムの基本構成

新しい創造などない。発見である！ (Gaudi)

- Mover**
- // 0: 時間
 - // 1: コスト
 - // 2: 定員
 - // 3: 近さ
 - // 4: 趣味・景色・歴史・名所・旧跡
 - // 5: 天候
 - // 6: 嗜好性・買物
 - // 7: 喫煙・飲酒
 - // 8: 食事
 - // 9: 遊具・スポーツ・マリナーリゾート
- その他拡張
100次元程度
.....

予測・推奨・マッチングの問題は発見により、共通化できる

効果・機能

① **EVマッチング+EV最適化**

- ・疲労軽減 (BigData可)
- ・健康 (BigData可)
- **快適 (BigData集積以前にトレンドがダイナミックに変わる)**

Trustee型協調フィルタと集合知により
Big Data集積以前に予測率を向上

③ **Moverコード**

個々の効果をユーザに応じて迅速に最適化するマッチング

LM
POI

User(Mover)

Web

② **FFLOW**

UEDB
UGC

Big Data集積以前にトレンドがダイナミックに変わる

- プラットフォームは異なるアプリで共通化
- ハードの構成: サイネージ + カメラ + センサ + PC
- データベース:
ユーザ体験 (UEDB)
ユーザ生成コンテンツ (UGC)

Moverから快適性へ

Moverコード

// 0: 時間重視

// 1: コスト

// 2: 定員(混雑回避)

// 3: 近さ(アクセス容易)

// 4: 趣味・景色・歴史・名所・旧跡 ==> 次元拡張?
(教養重視)

// 5: 天候 (快適重視)

// 6: 嗜好性・買物重視

// 7: 喫煙・飲酒

// 8: 食事(レストラン重視)

// 9: 遊具・スポーツ・マリンリゾート

//10: タクシー

//11: 徒歩(散策・運動重視)

//12: 路面電車・地下鉄・電車(低価格重視)

//13: バス(低価格重視)

//20: ●いったことがあるかどうか : 既体験度

//21: ●また行きたいかどうか : Repeater度

//25: ●エリアでベスト10に入るか: Best-10 priority

//28: ●エリアでベスト3に入るか?: Best-3 priority

.....

快適性ポテンシャル

$$\begin{aligned} \dot{E} &= \dot{U}_D \dot{U}_S^T \\ &= W(U_D, W_D) W(U_S, W_S)^T \end{aligned}$$

制約条件：日程、金、所要時間、レストラン、
周囲関連施設との行き来、連携、交通機関

突発条件：休館、工事中、天候、予定変更他

ユーザ条件：成熟度、リピート回数、親戚などの
宿泊条件、予定、レストランの好み、使用交
通機関、車種など。同乗者の好み、年齢、訪
問予定など。

車の快適性ポテンシャル

- 経路の正しさ、近さ、所要時間が妥当
- 混雑の少なさ
- 周囲景観の美しさ
- 適度に休憩場所がある
- 適度に観光スポットがある
- 適度に買い物ができる
- 運転が楽(道路幅、対向車、車線数、舗装度)
- 天候が良い
- 見通しが良い
- 危なくない
- 大型車が少ない
- 同乗者が退屈しない
- 乗員が全員、良好な体調を維持できる
- 要所要所に案内指示板があり、わかりやすい
- トンネルが走りやすい
-

CONNECTEDで全体の走りやすさを算出できる!?

どんなところへいく？

登録された経路リストから選ぶ

情流によるシーン検索

岬の灯台に続く、海岸線沿いのきれいな風景の道路

カンナの花がいっぱい咲いている道路

田園風景のきれいなカーブ

渋滞していない、夕暮れのフリーウェイを抜けて素敵なレストランへ

富士山が見える自動車専用道路から遊園地へ

阿蘇山をみわたせる広いパークウェイ

休日のショッピング、昼はレストランで、帰りは遊園地か公園で遊ぶ

.....

OK?



No

シーンから選ぶ

この段階ではPFLOWは確定していない

情流はイメージで駆動される

はりまや橋



五台山公園(ごだいさんこうえん)



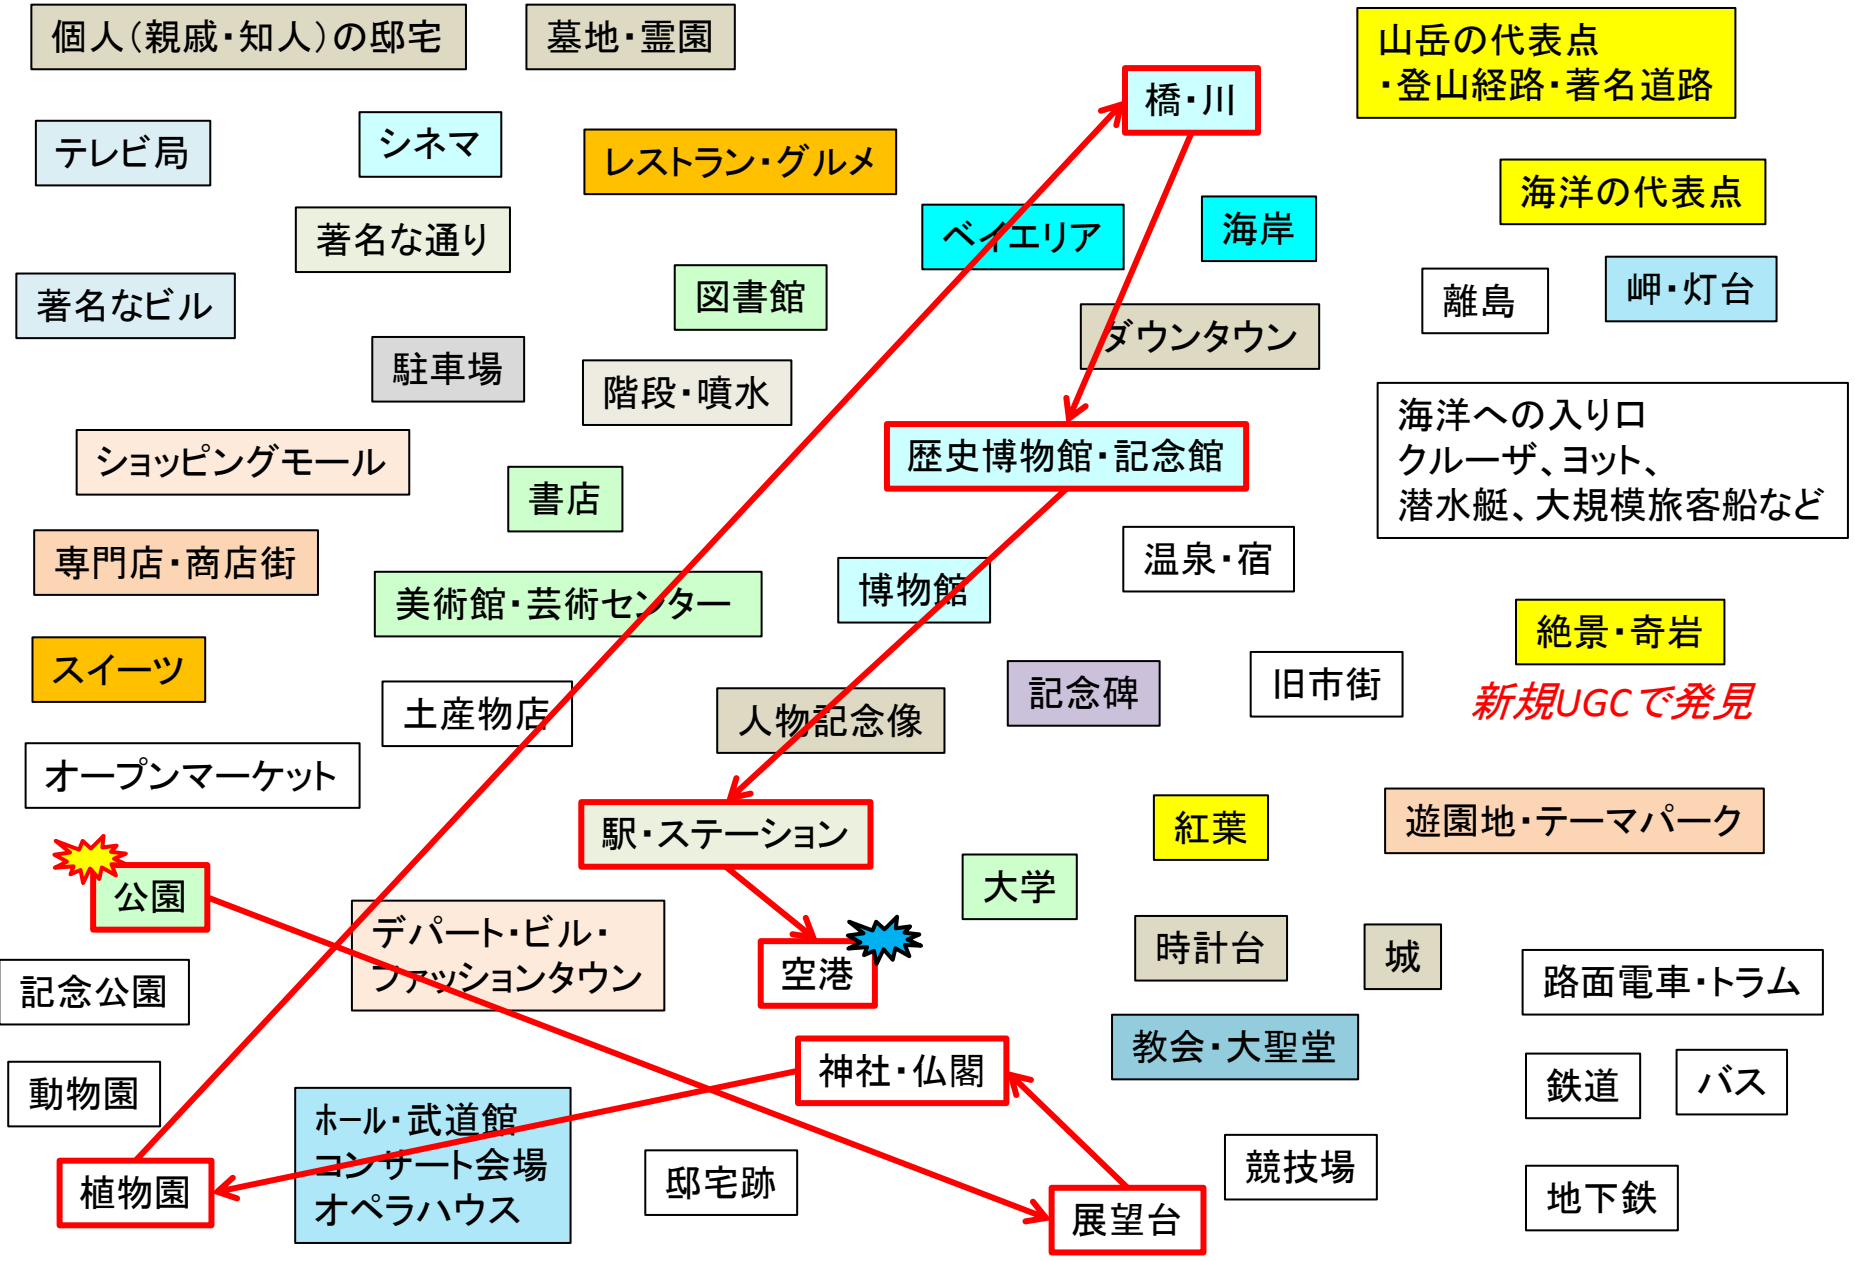
ひろめ市場



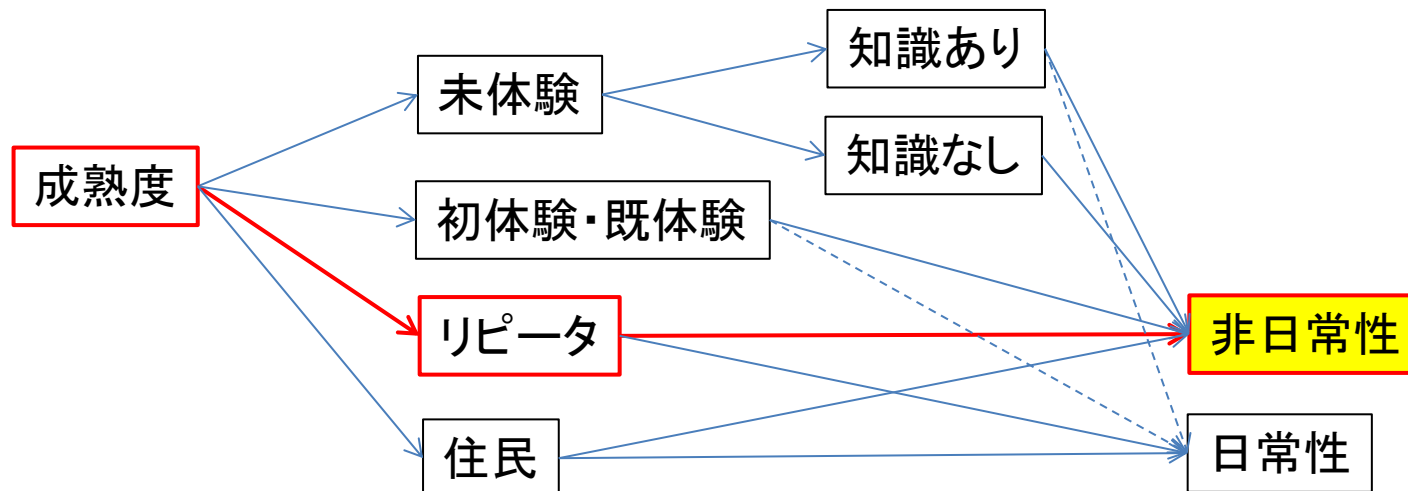
情流はイメージで駆動される



POIの基本定義から概略順序を決める




ユーザの成熟度



LMとユーザ分類に関する移動需要度と非日常性の推定値

	観光客			住民	交通手段
	未体験	初体験	リピータ		
名古屋イオンモール	H/M/L	非日常・H/M	非日常・M/L	日常・H	電車、車
名古屋ゲートタワー	H/M/L	非日常・H/M	非日常・H/M	日常・H	電車、車
栄・百貨店	H/M/L	非日常・H/M	非日常・M/L	日常・L	電車、車
アピタ・バロー	H/M/L	非日常・M/L	非日常・M/L	日常・M	車、徒歩
長崎・グラバー亭	H/M/L	非日常・H	非日常・H/M	日常・L	公共交通
高知・四万十エリア	H/M/L	非日常・H/M	非日常・H/M	日常・L	電車、バス、車



快適性のサービスイメージ



移動需要の浮動層をつかむ

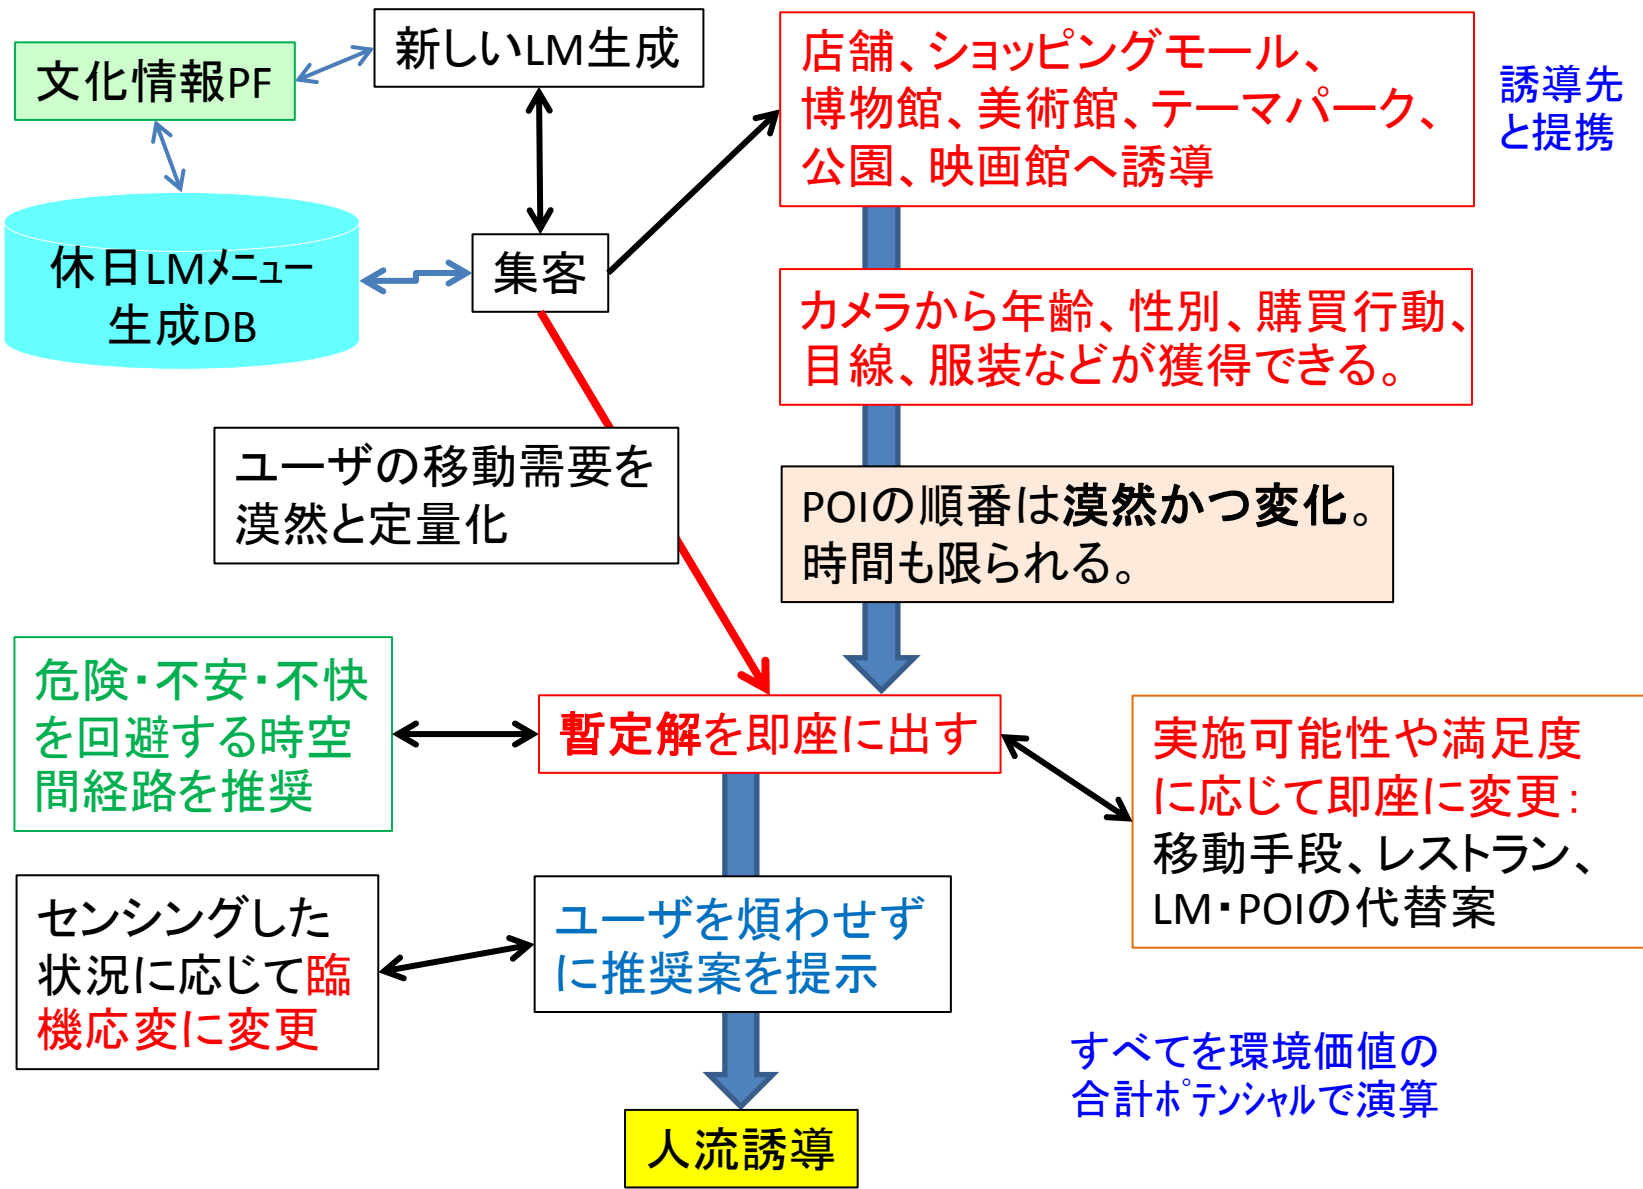
移動目的の内訳

移動需要の浮動層をつかむ

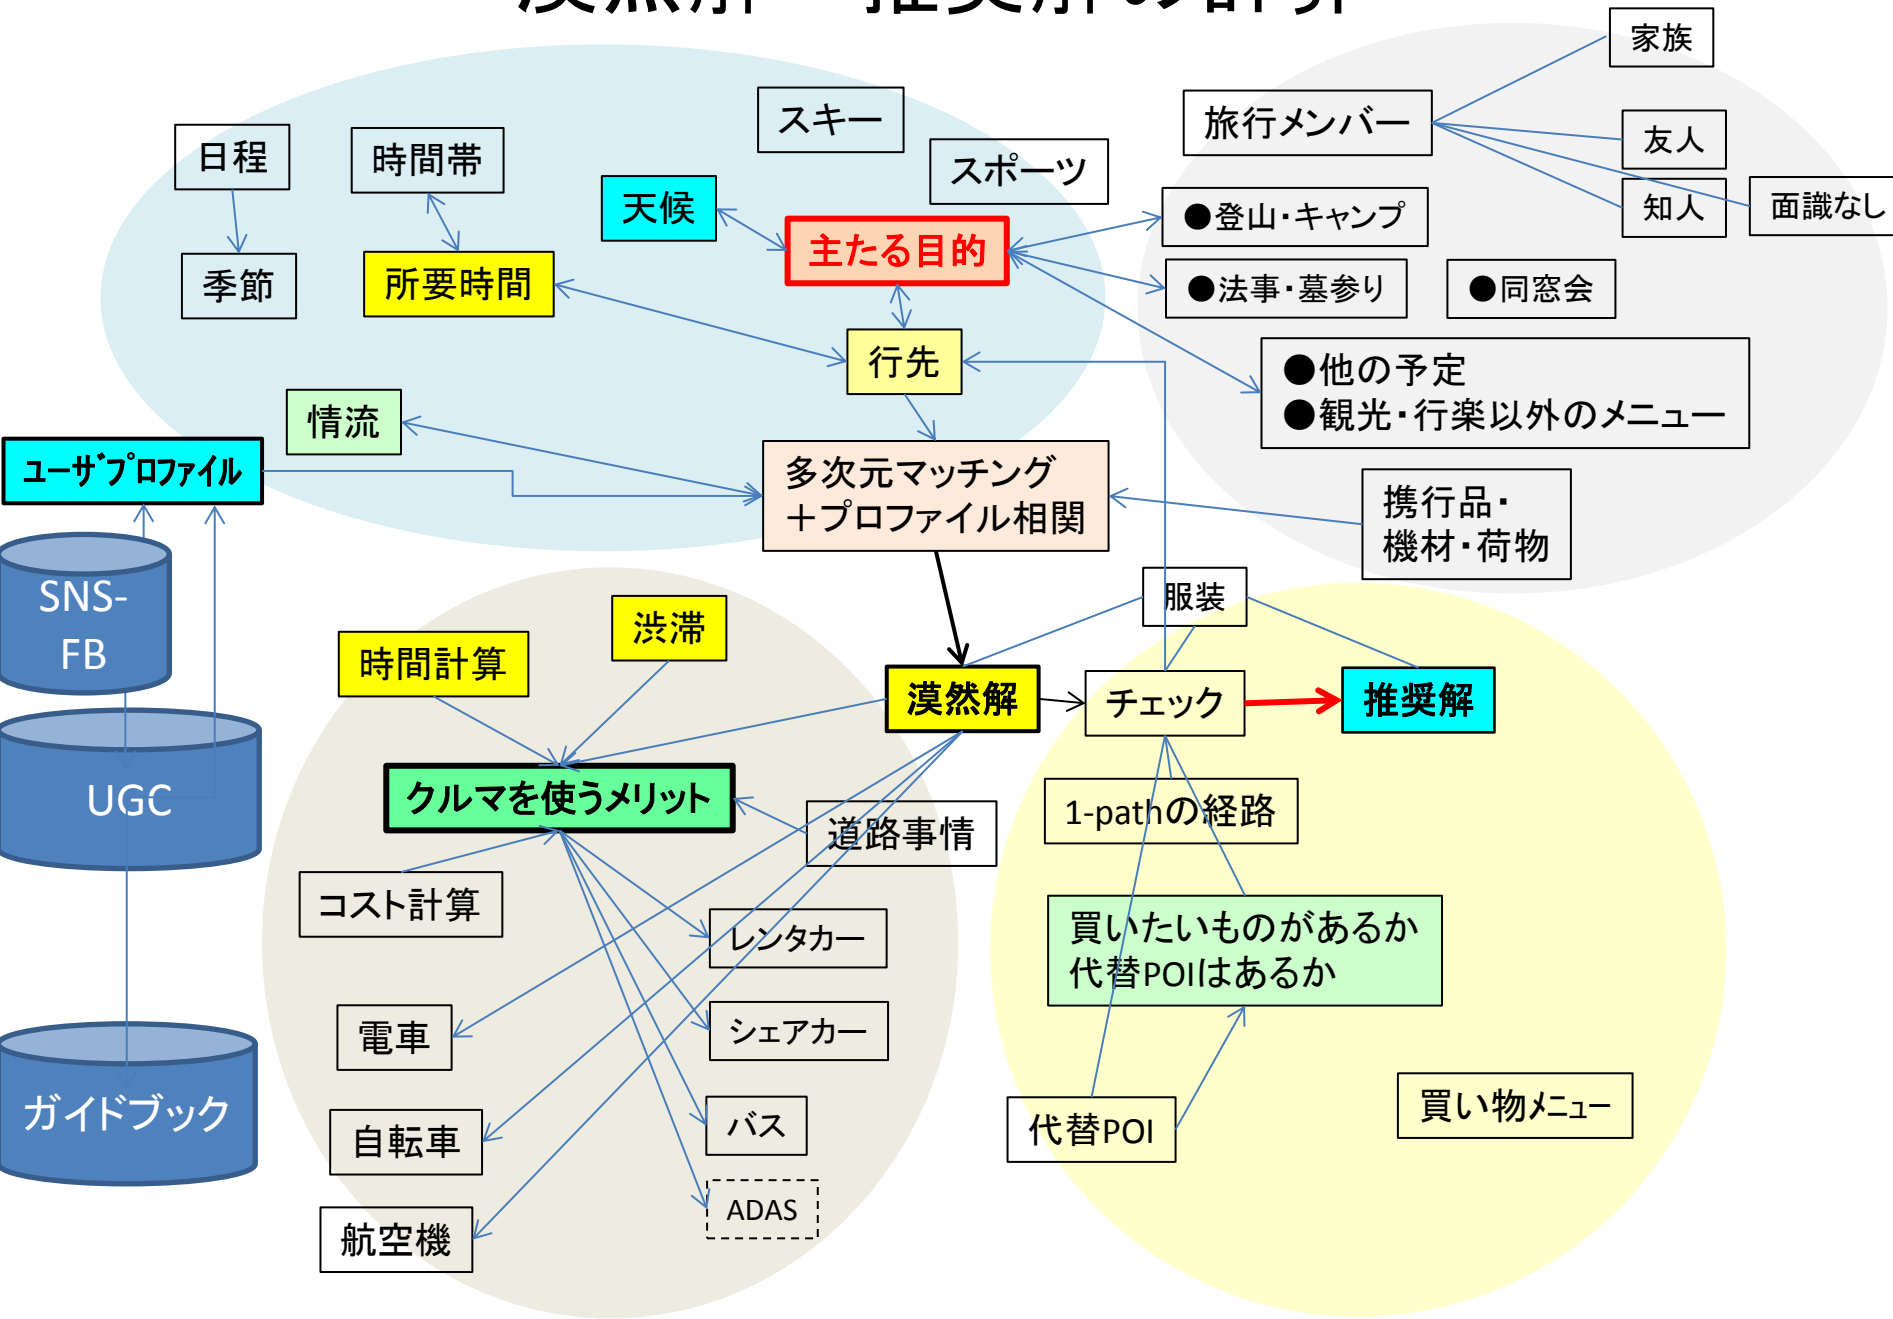


中京圏2011年11月5日(土)の2万人のPFLOWより名古屋駅周辺1km圏内を取り出して移動目的を分析した結果, 右図では“0: **その他**”が圧倒的に多い. これは{**漠然と移動**、**多目的**、**秘密**、**判定不能**}に相当する. 単位は「人・分」なので20000人分でもこのような値が出る.

人流をナビゲートする



漠然解～推奨解の計算



どういうデータを使うか

実例・実体験ベースで下記事例をDB化する：
ゴルフ、夏の予定、国内旅行、スキー他。イオン
モール、ジョギングなど。

さらに、FaceBook、ガイドブック他、過去の旅行体
験を順次UGC(ユーザ生成コンテンツ)化する。

まっふる、地球の歩
き方、ことりっふ、他

移動需要における**快適性**を
ユーザ体験で蓄積する：

- 家族と移動
- 音楽が聞ける
- 随時経路・POI変更可
- 積載量

快適性ポテンシャル: $E = E_{car} + E_{scene} + E_{poi} + E_{hmi}$

最初はマニュアル入力し、蓄積・分析後は自動予測する。
ユーザプロフィールやトレンドの影響があるので定型プラン以外はBigData
蓄積が期待できない。

- <ユーザ分類>
- 時間優先モデル
 - スケジュール厳守モデル
 - **レストラン予約重視モデル**
 - タクシー主導モデル
 - **電車バス優先+**
適宜タクシーモデル
 - **特定LM重視モデル**
 - コスト重視モデル
 - 雨天決行モデル
 - 快晴優先モデル
 - **買い物優先モデル**
 - 少し離れた一拠点重視モデル
 -

- 名古屋編：名駅GT他
- 国内編：沖縄・北海道他
- 海外編：香港、シンガポール他

情流はイメージで駆動される


桂浜



高知県立坂本龍馬記念館




土佐の青空市



桂浜



高知城



どう見せるか

事例0: ある休日の移動(簡易版)



天候、人数、重量物運搬、
駐車時間、他POI、カーシェア

FCourt: 30-40分
Restaurant: 60-90分

快適性のイメージ群提示
ユーザがパネル上で選択

ゴルフ、夏の予定、
国内旅行、スキー
他。イオンモール、
ジョギングなど。

標準スケジュール提
示(漠然解)

- <ユーザモデル>
- 時間優先モデル
 - スケジュール厳守モデル
 - レストラン予約重視モデル
 - タクシー主導モデル
 - 電車バス優先+適宜タクシーモデル
 - 特定LM重視モデル
 - コスト重視モデル
 - 雨天決行モデル
 - 快晴優先モデル
 - 買い物優先モデル
 - 少し離れた一拠点重視モデル
 -

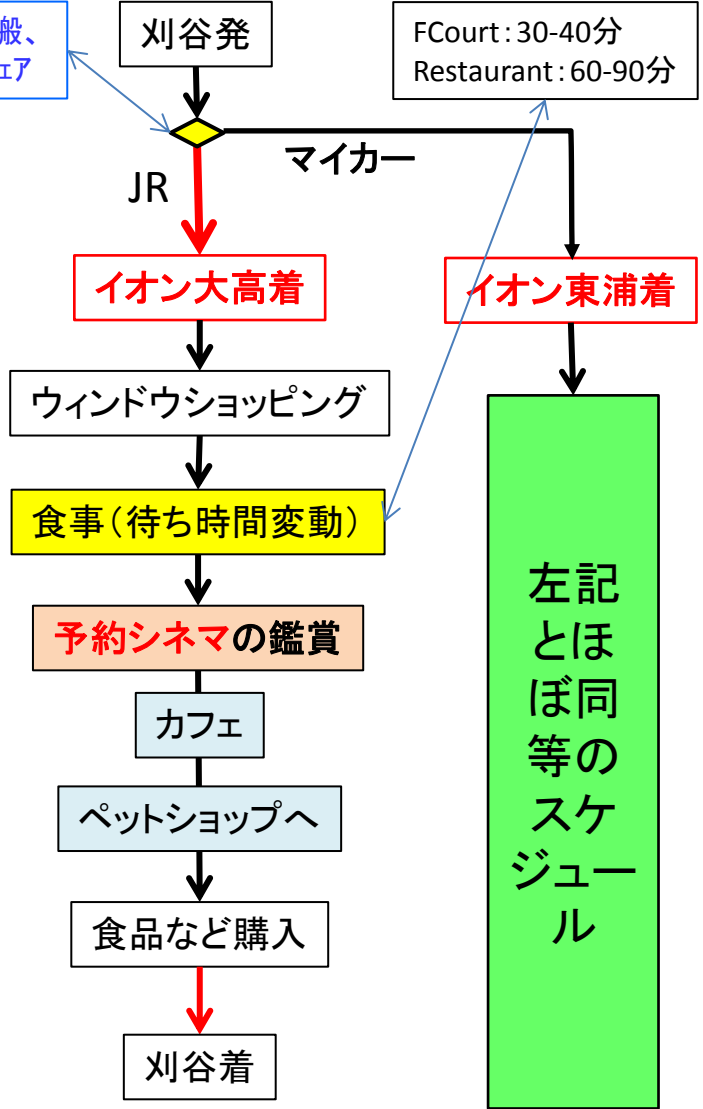
移動需要における(クルマの)快適性を予測

移動目的や嗜好性から
MoverとPOIをマッチング

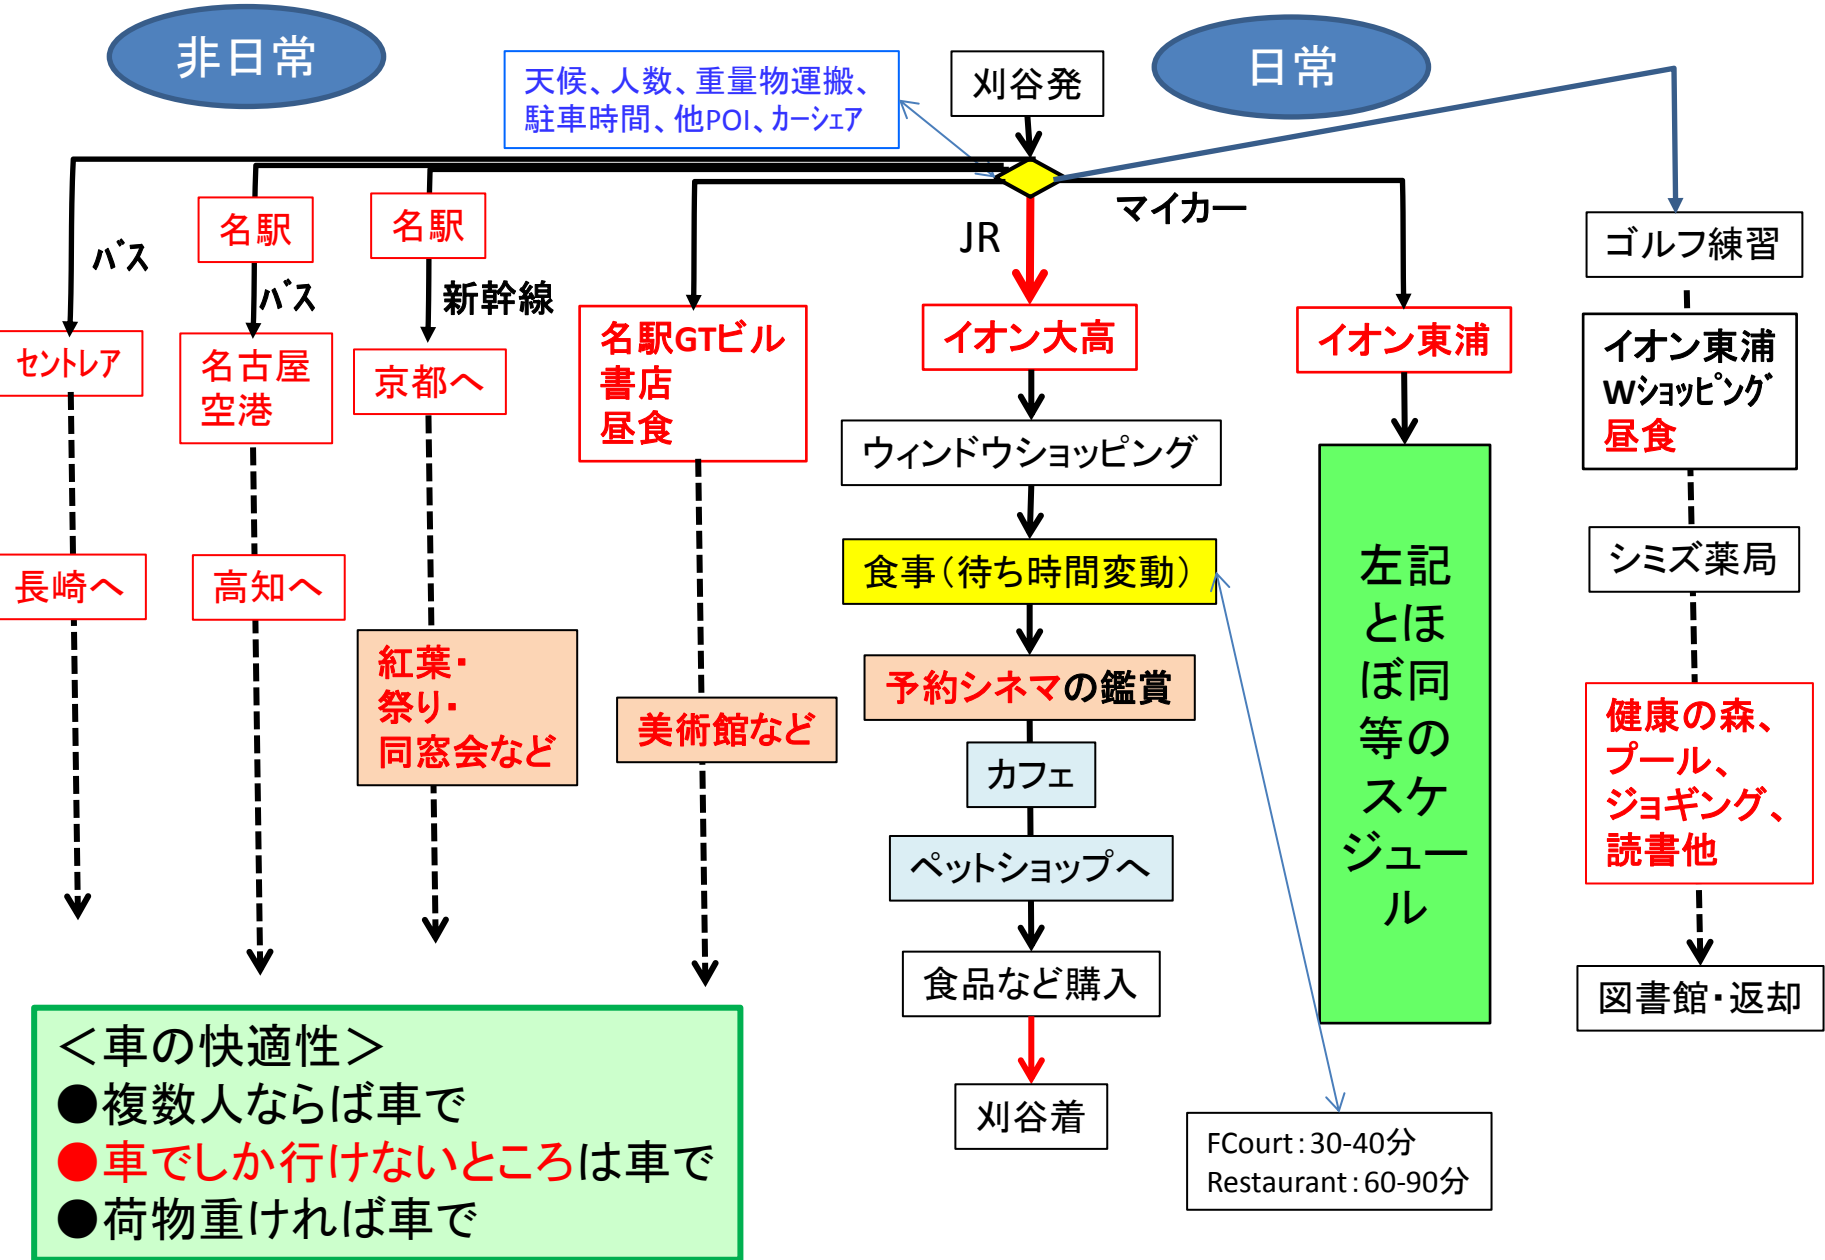
Moverは承認? **No**



未分類のイメージ群をラベルと共に学
習・伝搬し、新しいクラスを形成できる
IEEE-PAMI_201707.pp.1360



事例0: ある休日の移動(詳細版)



臨機応変にスケジュールを修正する



1st Day



©Tourisme Montréal/Jean-F. Leblanc

2nd Day



まずは漠然と、時間をかけずに

～ 思いをデータ化する ～

0:食事:JRGT、AE、
 1:通勤通学:自
 2:買物:JRGT、AE大高
 3:仕事:本、PC、医者
 4:行楽:絵画、公園、運動

制約:混雑回避
 待ち時間極小化

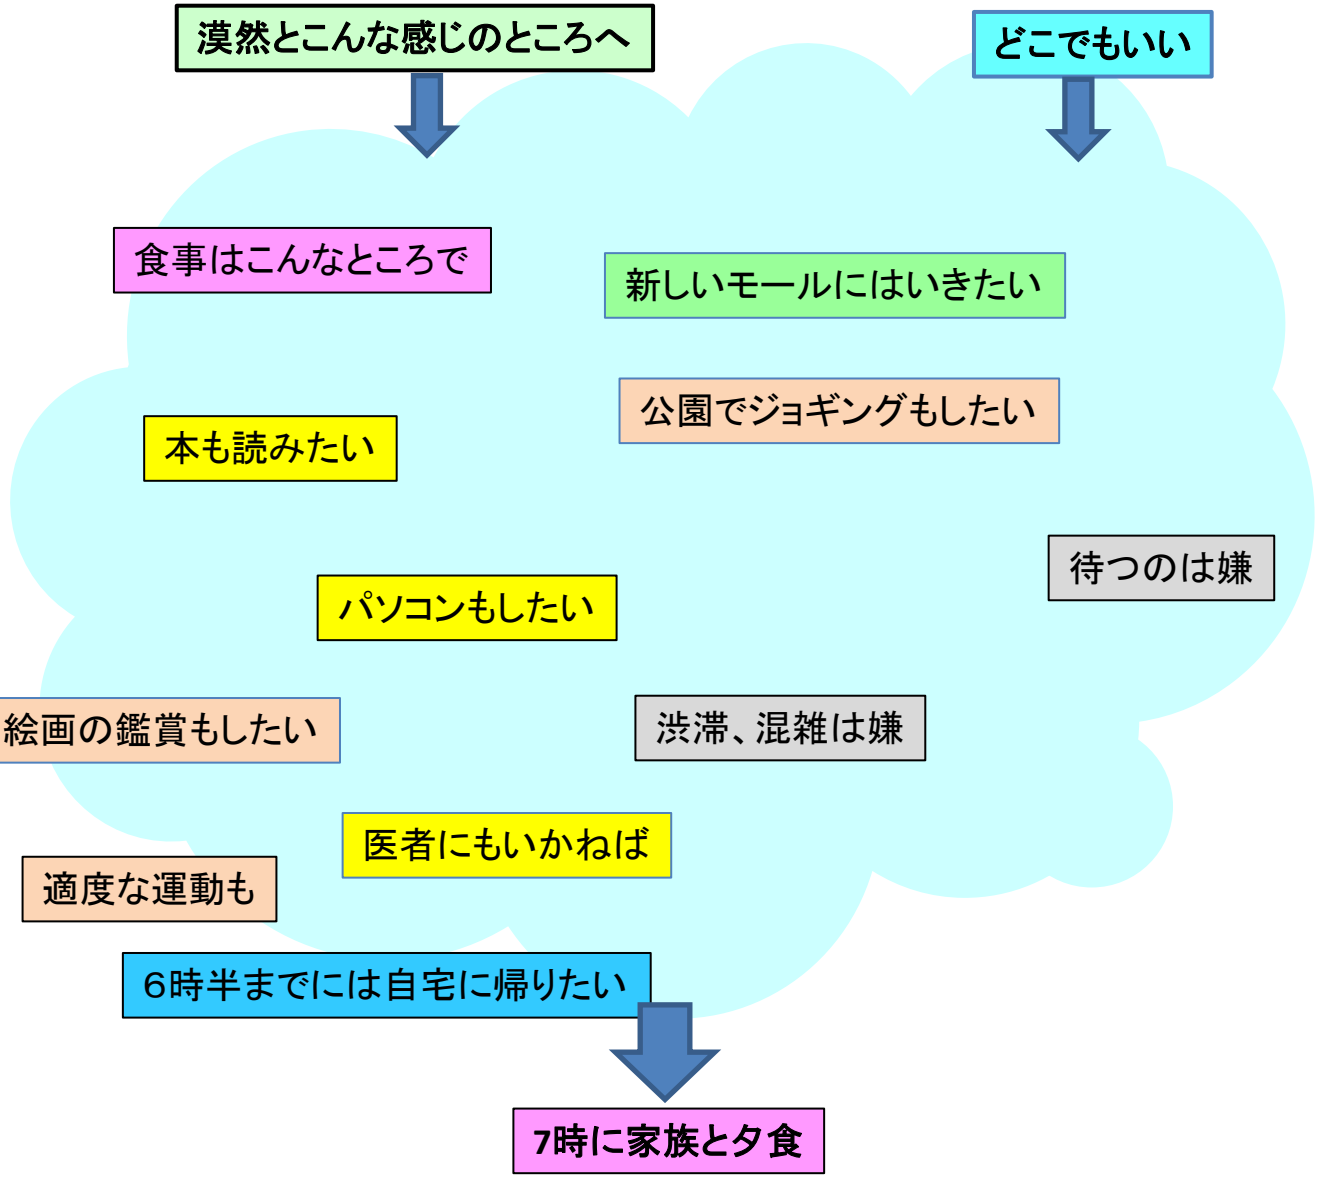


●移動需要は5カテゴリで

0:Eating,
 1:Commuting
 2:Shopping,
 3:Working,
 4:Leisure

●1日の時間帯は5分割


time zone No.	hour
0	5am-10am
1	10am-12am
2	12am-3pm
3	3pm-6pm
4	6pm-5am



暫定スケジュールの評価

中京圏休日14万人(2011)


正規化目的ベクトル(名駅)



正規化では混雑度は予想できない

中京圏休日14万人(2011)

非正規化目的ベクトル(名駅)




名駅の時間帯 目的

予想混雑度


スケジュール通りにT3で行っても混雑が予想される

時間帯をずらしても混雑が予想される



各駅の時間帯
Usr2の時間帯

Usr2の正規化スケジュール (t1で再計算・修正)



Usr2の時間帯 目的

事例1:GWに長崎、博多へ観光旅行

5月5日:長崎 グラバー亭、ちゃんぽん、長崎博物館
 5月6日:長崎 亀山社中、龍馬像、稲佐山
 5月7日、8日AM:博多

★公共交通・タクシーの快適性
 ★Moverの属性
 ★ユーザ分類をコード化で対応付け

【主要条件】
 ●個人イベント
 ●天候
 ●荷物(帰り含む)
 ●公共交通の値段
 ●移動する人数:1
 ●道路事情
 ●所要時間
 ●服装
 ●時間帯
 ●買いたいもの
 ●代替POI
 ……………

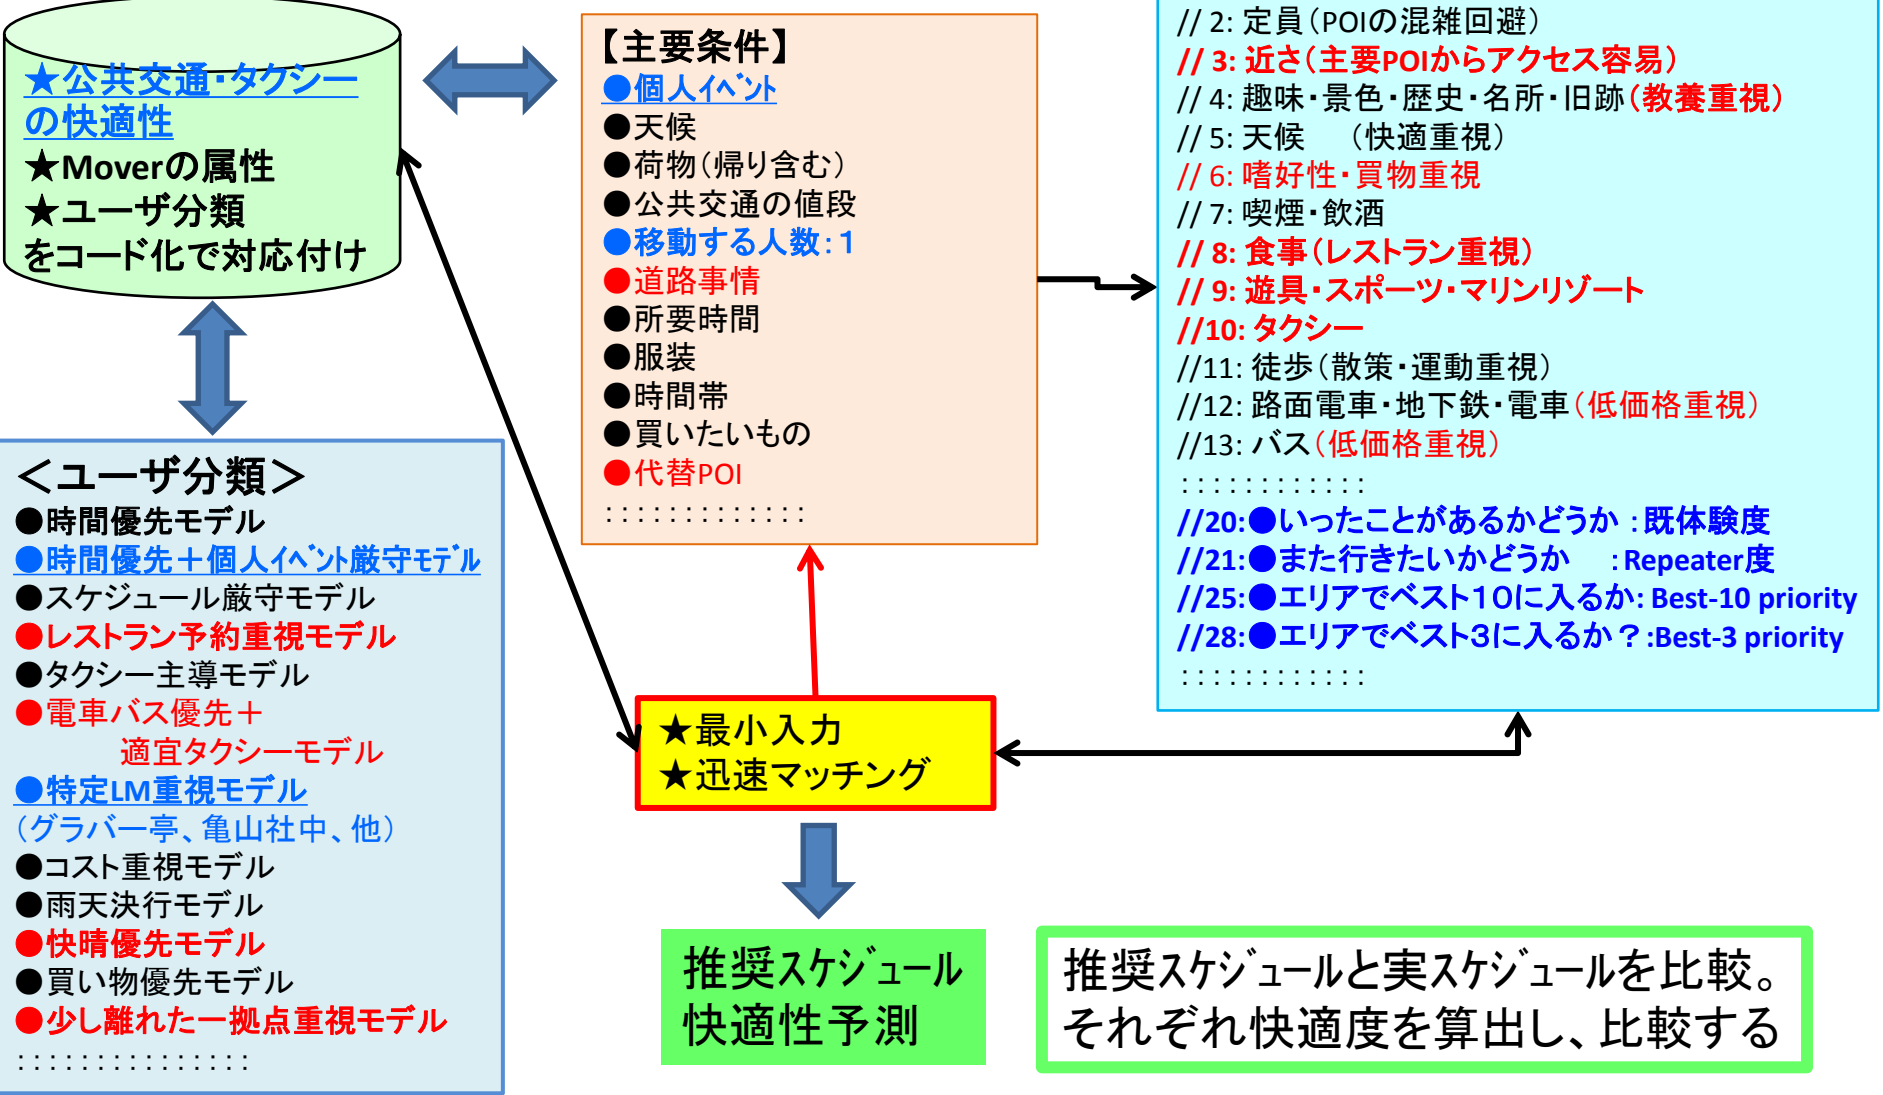
<Moverベクトル>
 // 0: 時間重視
 // 1: コスト
 // 2: 定員(POIの混雑回避)
 // 3: 近さ(主要POIからアクセス容易)
 // 4: 趣味・景色・歴史・名所・旧跡(教養重視)
 // 5: 天候 (快適重視)
 // 6: 嗜好性・買物重視
 // 7: 喫煙・飲酒
 // 8: 食事(レストラン重視)
 // 9: 遊具・スポーツ・マリリゾート
 // 10: タクシー
 // 11: 徒歩(散策・運動重視)
 // 12: 路面電車・地下鉄・電車(低価格重視)
 // 13: バス(低価格重視)
 ……………
 // 20: ●いったことがあるかどうか : 既体験度
 // 21: ●また行きたいかどうか : Repeater度
 // 25: ●エリアでベスト10に入るか: Best-10 priority
 // 28: ●エリアでベスト3に入るか?: Best-3 priority
 ……………

<ユーザ分類>
 ●時間優先モデル
 ●時間優先+個人イベント厳守モデル
 ●スケジュール厳守モデル
 ●レストラン予約重視モデル
 ●タクシー主導モデル
 ●電車バス優先+適宜タクシーモデル
 ●特定LM重視モデル
 (グラバー亭、亀山社中、他)
 ●コスト重視モデル
 ●雨天決行モデル
 ●快晴優先モデル
 ●買い物優先モデル
 ●少し離れた一拠点重視モデル
 ……………

★最小入力
 ★迅速マッチング

推奨スケジュール
 快適性予測

推奨スケジュールと実スケジュールを比較。
 それぞれ快適度を算出し、比較する



事例2: 夏休み前半に親族訪問、墓参り、観光

8月11日(金)、12日(土): 高知・四万十エリアをレンタカーで移動、親族訪問、墓参り、観光
 8月13日(日): 四万十エリアから高知駅前、親族訪問、レンタカー返却、夕食、従兄と別れ、ホテルC
 8月14日(月): 高知市内を公共交通で観光

★クルマの快適性
 ★Moverの属性
 ★ユーザ分類
 をコード化で対応付け

【主要条件】
 ●個人イベント(墓参り、挨拶他)
 ●天候
 ●荷物(帰り含む)
 ●公共交通の値段
 ●移動する人数: 2
 ●道路事情
 ●所要時間
 ●服装
 ●時間帯
 ●買いたいもの
 ●代替POI
 ……………

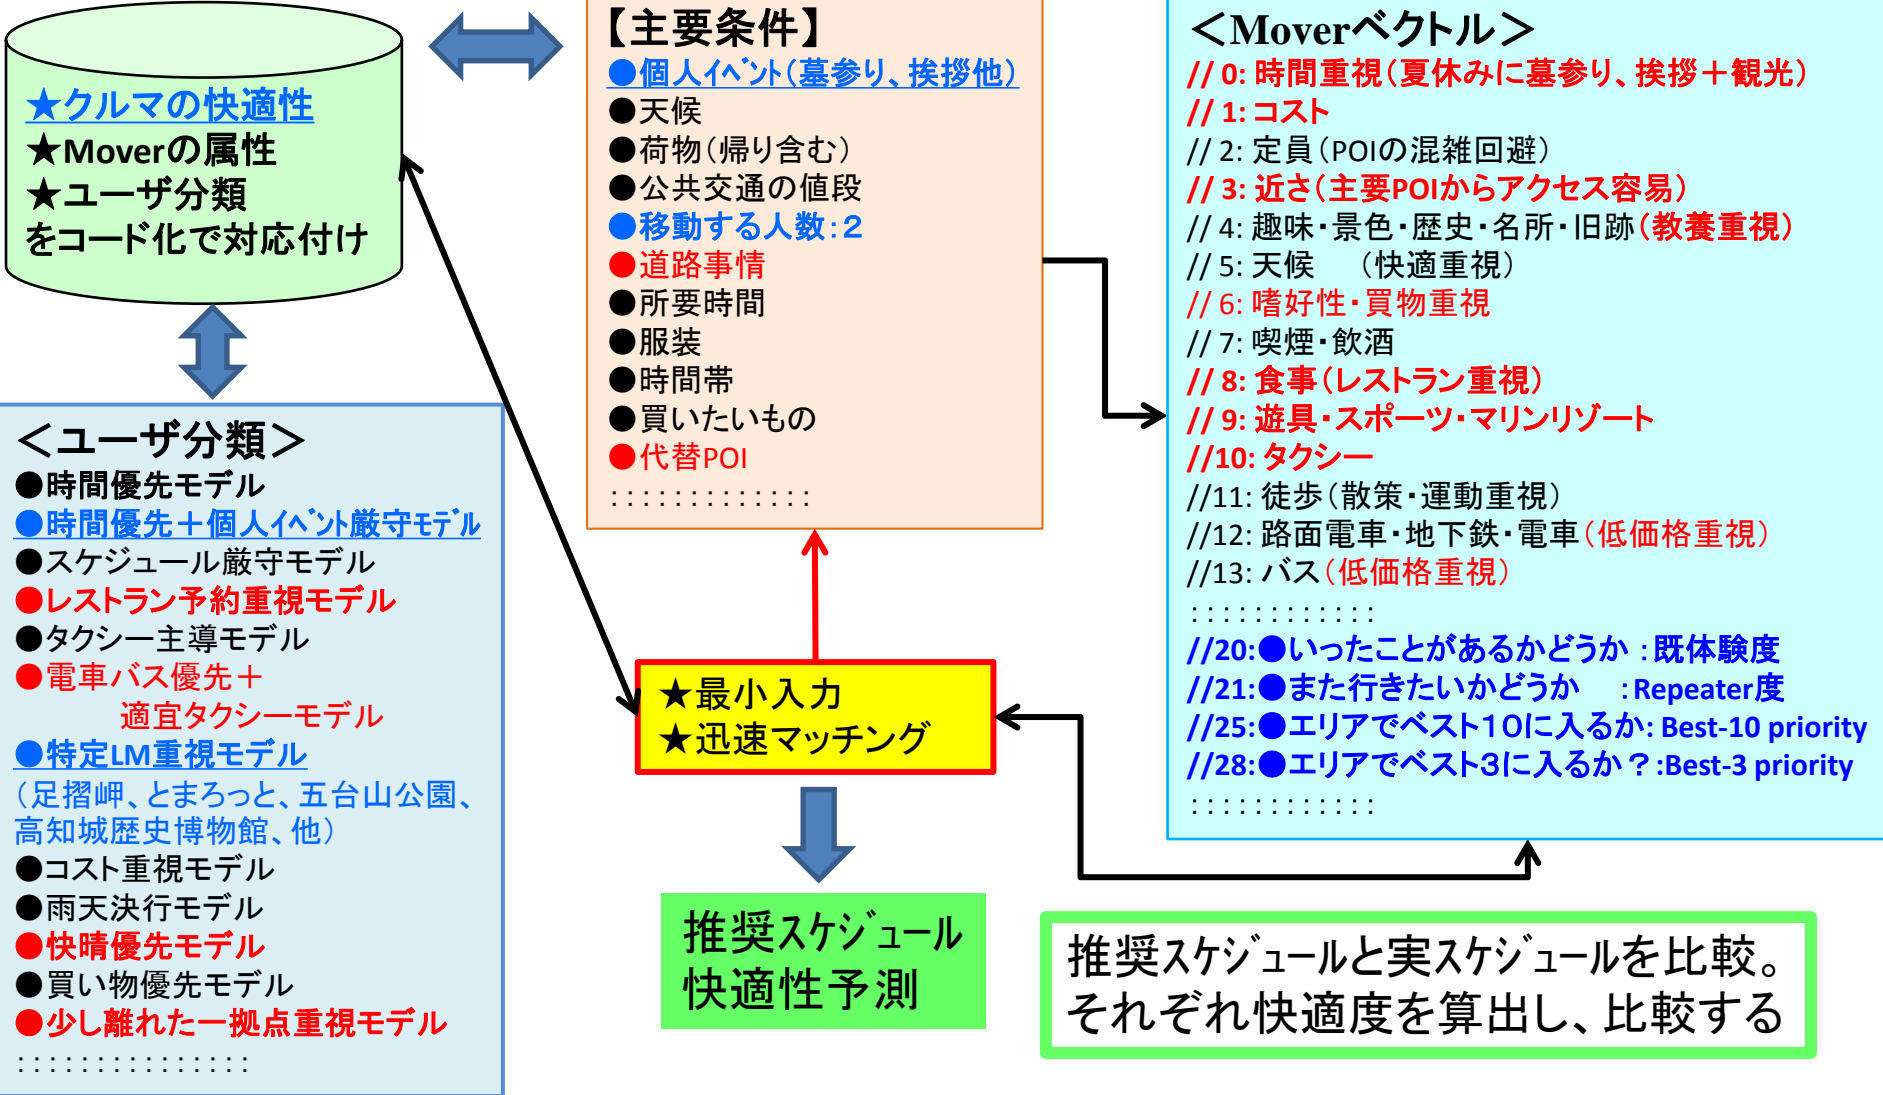
<Moverベクトル>
 // 0: 時間重視(夏休みに墓参り、挨拶+観光)
 // 1: コスト
 // 2: 定員 (POIの混雑回避)
 // 3: 近さ(主要POIからアクセス容易)
 // 4: 趣味・景色・歴史・名所・旧跡(教養重視)
 // 5: 天候 (快適重視)
 // 6: 嗜好性・買物重視
 // 7: 喫煙・飲酒
 // 8: 食事(レストラン重視)
 // 9: 遊具・スポーツ・マリニリゾート
 // 10: タクシー
 // 11: 徒歩(散策・運動重視)
 // 12: 路面電車・地下鉄・電車(低価格重視)
 // 13: バス(低価格重視)
 ……………
 // 20: ●いったことがあるかどうか : 既体験度
 // 21: ●また行きたいかどうか : Repeater度
 // 25: ●エリアでベスト10に入るか: Best-10 priority
 // 28: ●エリアでベスト3に入るか? : Best-3 priority
 ……………

<ユーザ分類>
 ●時間優先モデル
 ●時間優先+個人イベント厳守モデル
 ●スケジュール厳守モデル
 ●レストラン予約重視モデル
 ●タクシー主導モデル
 ●電車バス優先+適宜タクシーモデル
 ●特定LM重視モデル
 (足摺岬、とまろっと、五台山公園、高知城歴史博物館、他)
 ●コスト重視モデル
 ●雨天決行モデル
 ●快晴優先モデル
 ●買い物優先モデル
 ●少し離れた一拠点重視モデル
 ……………


★最小入力
 ★迅速マッチング

推奨スケジュール
 快適性予測

推奨スケジュールと実スケジュールを比較。
 それぞれ快適度を算出し、比較する



選好順位と快適性で迅速に推奨



選好順位のみで
一次振り分け


各事象の適合度を移動需要の観点で
多属性評価し、現時点の最終判断を下す

多次元EVマッチング

$N < NEV$ (EVのキャパシティ)
でマッチング充足

EV = $X_{purp1} X_{purp2}$



内積相関



移動需要場
の評価と同じ

プロフィール間相関

ユーザ属性間相関



ユーザ数 $M < NEV$ の場合

Pref1(m,l)

Pref2(l,m)

UsrDA[i][j]

UsrSA[k][j]

ユーザのLM
選好順位


LMのユーザ
選好順位

ユーザ目的
ベクトル

LM属性ベクトル

静的ユーザ属性
プロフィール


動的ユーザ属性
プロフィール



- // 0: 時間
- // 1: コスト
- // 2: 定員
- // 3: 近さ
- // 4: 趣味・景色・歴史・名所・旧跡
- // 5: 天候
- // 6: 嗜好性・買物
- // 7: 喫煙・飲酒
- // 8: 食事
- // 9: 遊具・スポーツ・マリンリゾート

Moverコード

選好順位と快適性ポテンシャルによる評価例



今後の拡張プラン

①信頼度ネットワークを用いた協調フィルタリングにより、少数でも予測精度を上げる:

Bo Yang, et al., "Social Collaborative Filtering by Trust", *IEEE Trans. PAMI*, Aug.2017.

②未知画像への自動ラベル伝搬: Guo-Jun Qi, et al., "Joint Intermodal and Intramodal Label Transfers for Extremely Rare or Unseen Classes", *IEEE Trans. PAMI*, July 2017.

① Trustee Model




Figure 1: A sample social rating network.




Fig. 2. (a) Trustee model $B^T V$: How others affect user i 's opinions. (b) Trustee model $W^T V$: how others follow user i 's opinions.

ビッグデータ集積以前の推奨には
風評のTrusteeモデルを適用できる!

2.3.2 Trustee Model

Fig. 2b shows the proposed trustee model that is able to characterize how a user i 's opinions affect the decisions of others who trust i by means of $W_i^T V_j$. Distinct from the truster model, this time we choose the trustee-specific feature matrix W as the latent space commonly shared by R and T , meaning the user feature matrix U is approximated by the trustee feature matrix W . In the trustee model, vector W_i simultaneously characterizes two meanings: how a user

i is trusted (or followed) by others, and how the same user i rates items. Specifically, the item-specific latent feature vector V_j depends on the items rated by users. Together, the $W_i^T V_j$ indicates how other users follow user i to rate item j , which is the approximation of real score R_{ij} as well. Similarly, one can learn the feature matrices W , V and B simultaneously by minimizing the following objective:

$$\begin{aligned} \mathcal{L} = & \sum_{(i,j) \in \Omega} (g(W_i^T V_j) - R_{ij})^2 + \sum_{(k,i) \in \Psi} (g(B_k^T W_i) \\ & - T_{ki})^2 + \lambda (\sum_i (n_{w_i} + m_{w_i}) \|W_i\|_F^2 \\ & + \sum_j n_{v_j} \|V_j\|_F^2 + \sum_k m_{b_k} \|B_k\|_F^2), \end{aligned} \quad (5)$$

where n_{w_i} and n_{v_j} denote the number of ratings given by user i and given to item j , respectively, m_{w_i} is the number of users who trust user i and m_{b_k} is the number of users who are trusted by user k .

情流が人流を駆動するとき

- 個々のユーザの**仮想時空間**は、**実移動・体験・会話**を通じ、**かぎりなく実空間に漸近**する。
- ただし、必要な範囲のみ。歩いた床の下に何があったか、過ぎ去った建物の中など、普通は考えもしない。**一生、知らなくていい真値も多い**。

適度な**集合知**に基づく認識結果以外は**漠然解**である。
確信度・漠然度の中でシステムの進化と予定遂行がなされる。

快適性をもとに**仮想時空間内の移動需要予測**、
 即ち、**自律的な移動意思の時系列**が生成される。

情流に残る**仮想時空間**は**漠然**としたイメージ

このイメージが**人流のトリガー**になる：
情流推定を用いた人流予測

これを機械が
 機械のために
 やると？

機械の情流を推定 →
 機械の**実流**の予測 →
 機械の**移動意思**の決定

- 人間に適用すると、**人流の円滑化・意思決定の迅速化**に寄与する
- 車載器では運転者に**余裕の時間**を生む

- **機械の情流**は機械の**発想・創造力**を生成。
- **快適性ポテンシャル**をベースに**創造力**を持つ**コンピュータ**が出現する。

おわりに

- **快適性**を中心とする移動需要予測について提案した。
- POIやランドマークの**環境価値を表すベクトルMover**を提案し、快適性ポテンシャルと選好順位に基づく**統合評価**を試みた。
- **情流**の概念を提案し、人流との関係を考察した。

今後の予定

- 情流 (Feeling Flow) という観点の人流誘導を想定し、**漠然解の迅速な提示により混雑回避、快適性向上**を目指す。
まずは自分の移動体験DBを評価する。
- **ロボットや自動運転車の時空間移動経路に際して、時系列意思決定の問題に、情流予測からアプローチする。**

本発表掲載の写真は一部、下記サイトより転載。

沖縄観光の人気スポットランキングTOP30！ | 楽天トラベル

京都の観光スポットランキングTOP10 - じゃらんnet

四国 高知県の一度は行ってみたい 絶景観光スポット - NAVER まとめ

東京の観光スポットランキングTOP10 - じゃらんnet

北米のパリと呼ばれる街、モントリオール | カナダの観光情報サイト「ENJOY CANADA」 | H.I.S.関西発

シャープならデジタルサイネージの機材選定から設置・施工、運用、保守まで一括サポート:シャープ

Thank you for your attention.