

場所概念転移学習モデルの名前・位置予測における 大規模性能評価実験

Large-Scale Performance Evaluation Experiments on Name and Location Prediction of Spatial Concept Transfer Learning Model

田口慶志郎
Keishiro Taguchi

浅田和弥
Kazuya Asada

石伏智
Satoshi Ishibushi

萩原良信
Yoshinobu Hagiwara

谷口忠大
Tadahiro Taniguchi

立命館大学
Ritsumeikan university

Spatial concept transfer learning model was first for the purpose of transferring the knowledge of places acquired in learning environments when the robot moves to new environments. However, in previous studies, this model has not proven to be effective for transferring the knowledge of places to new environments. Therefore, in this paper, we conduct large-scale performance evaluation experiments on name and localization prediction of this model in new environments and we verify whether this model is effective for transferring knowledge of places to a new environment. The experiment results on a larger scale showed that the model has a effectively a high prediction performance of name and location in new environments, and can indeed transfer the knowledge of prior places.

1. はじめに

新規環境で動作するロボットが予め一般的な場所の知識を保持していることで、ユーザはロボットにその場所に関する知識を少量与えるだけで良く、場所の名前を教示するという負担を減らすことに繋がる。近年、サービスロボットや家庭内ロボットといった人と共同で生活するロボットの需要が高まっている。このようなロボットが人間からの「キッチンからお皿を持ってきて」というような指示を遂行するためには、キッチンという単語からキッチンを表す座標や空間を推定できることが必要である。

ロボットに場所の知識を獲得させる研究として、ナビゲーションの分野で場所の認識を行う手法 [Kostavelis 13] や場所の名前や場所の空間的領域を場所概念と捉え、ロボットに場所概念を形成させる手法 [Taniguchi 16] [Ishibushi 16a] が提案されている。これらの手法の問題点として、形成した場所概念を新規環境に転移することができず、環境が変わるごとにデータを観測し、改めて場所概念を形成する必要があり、学習面で非効率であることが挙げられる。そこで、石伏はある場所で形成した場所概念を新規環境における場所概念の形成に転移するモデルを提案した [Ishibushi 16b]。しかし、石伏の実験では実環境でロボットに場所概念を学習させているため、4環境での転移学習にとどまっていた。そこで、浅田は仮想環境として SIGVerse [Inamura 10] を用いて、クラウド概念学習システムを構築した [Asada 16]。

そこで、本研究では、クラウド仮想環境を用いた場所概念転移学習モデルによる大規模な性能評価実験を場所の名前と位置の予測において実施する。図1は、本研究の概要図である。大規模な環境で形成した場所概念を新規環境に転移することで、ロボットは新規環境において観測情報から場所の名前を予測したり、人間から与えられた場所の名前からその場所の位置を予測する。

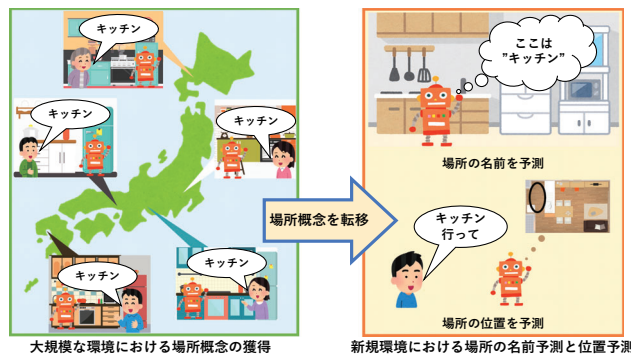


図 1: 本研究の概要図

2. 手法

2.1 場所概念転移学習モデルの概要

図2に場所概念転移学習モデルのグラフィカルモデルを、表1にグラフィカルモデルの各変数の定義を示す。このモデルは、ある環境でロボットが学習した場所概念を新規環境の学習に用いることができないことが学習面で非効率であり、ユーザが場所の名前などを最初から全て教示しなければならないという問題を解決するために提案されたものである。また、このモデルでは、学習環境と新規環境に共通したパラメータ ϕ^v, ϕ^n を有することで、新規環境に学習環境で形成した場所概念を転移することができる。

2.2 観測情報の取得

場所概念転移学習モデルは、観測情報として画像情報 v_t 、場所の名前情報 n_t 、自己位置情報 x_t を取得する。画像情報は、ロボットが取得した画像を Convolutional Neural Network のフレームワークの1つである Caffe [Jia 14] に入力し、Softmax関数からの出力を 1000次元の画像特徴ベクトルとして取得する。Caffeのパラメータは、事前に ImageNet Large Scale Visual Recognition Challenge 2012 のデータセットを使用し

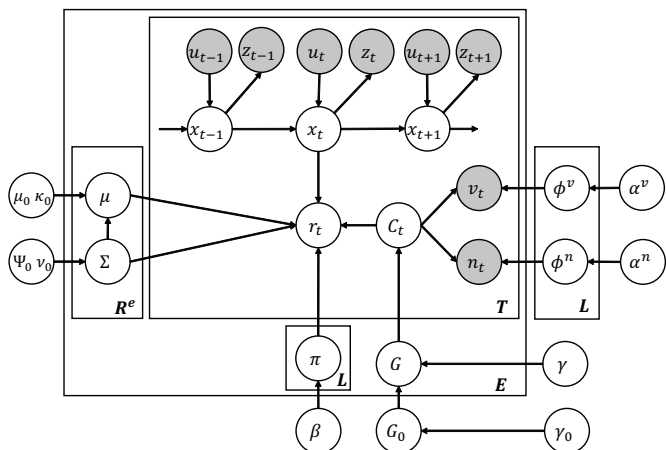


図 2: 場所概念転移学習モデルのグラフィカルモデル

て学習されている*1。場所の名前情報は、人間から与えられる場所に関する発話文に含まれる語彙を Bag-of-Feature として取得する。自己位置情報は、Monte Carlo Localization によって取得する。ただし、本実験では、クラウド仮想環境から取得されるオドメトリ情報から自己位置を推定した。

2.3 パラメータの推定

場所概念転移学習モデルにおけるパラメータ $r_t, C_t, \mu, \Sigma, \pi, G, \phi^v, \phi^n, G_0$ は、以下のようにギブスサンプリングによって推定する。このようなサンプリングを予め決められた回数だけ、イテレーションを行う。

$$r_t^e \sim p(r_t^e = k | x_t^e, C_t^e = l, \mu^e, \Sigma^e, \pi^e) \quad (1)$$

$$\propto \mathcal{N}(x_t^e | \mu_k^e, \Sigma_k^e) \text{Mult}(r_t^e = k | \pi_l^e) \quad (2)$$

$$C_t^e \sim p(C_t^e = l | x_t^e, v_t^e, n_t^e, r_t^e = k, \mu^e, \Sigma^e, \phi^v, \phi^n, G^e) \quad (3)$$

$$\propto \text{Mult}(v_t^e | \phi_l^v) \text{Mult}(n_t^e | \phi_l^n) \\ \times \mathcal{N}(x_t^e | \mu_k^e, \Sigma_k^e) \text{Mult}(C_t^e = l | G^e) \quad (4)$$

$$\mu_k^e, \Sigma_k^e \sim p(\mu_k^e, \Sigma_k^e | r_t^e = k, \mathbf{X}^e, \mu_0, \kappa_0, \Psi_0, \nu_0) \quad (5)$$

$$\propto \mathcal{N}\mathcal{I}\mathcal{W}(\mu_k^e, \Sigma_k^e | \mu_{n_k}, \kappa_{n_k}, \Psi_{n_k}, \nu_{n_k}) \quad (6)$$

$$\pi_l^e \sim p(\pi_l^e | r^e, C_l^e, \mathbf{X}^e, \mu^e, \Sigma^e, \beta) \quad (7)$$

$$\propto \text{Dir}(\pi_l^e | \beta_{new}) \quad (8)$$

$$G^e \sim p(G^e | C^e, G_0, \gamma) \quad (9)$$

$$\propto \text{Dir}(G^e | \gamma_{new} G_0) \quad (10)$$

$$\phi_l^v \sim p(\phi_l^v | C_l, \mathbf{V}, \alpha^v) \quad (11)$$

$$\propto \text{Dir}(\phi_l^v | \alpha_{new}^v) \quad (12)$$

$$\phi_l^n \sim p(\phi_l^n | C_l, \mathbf{N}, \alpha^n) \quad (13)$$

$$\propto \text{Dir}(\phi_l^n | \alpha_{new}^n) \quad (14)$$

$$G_0 \sim p(G_0 | \mathbf{G}, \gamma, \gamma_0) \quad (15)$$

$$\propto \text{Dir}(G_0 | \gamma_{0,new}) \quad (16)$$

表 1: グラフィカルモデルの各変数の定義

x_t	ロボットの自己位置
z_t	距離センサからの観測情報
u_t	制御情報
v_t	観測した画像情報
n_t	観測した場所の名前情報
r_t	位置分布のインデックス
C_t	場所概念のインデックス
μ, Σ	位置分布パラメータ (平均ベクトル, 共分散行列)
ϕ^v	画像情報の多項分布のパラメータ
ϕ^n	場所の名前情報の多項分布のパラメータ
π	r_t の多項分布のパラメータ
G, G_0	C_t の多項分布のパラメータ
α^v	ϕ^v のディリクレ事前分布のハイパーパラメータ
α^n	ϕ^n のディリクレ事前分布のハイパーパラメータ
β	π のディリクレ事前分布のハイパーパラメータ
μ_0, κ_0	ガウス・逆ウィシャート分布の
Ψ_0, ν_0	ハイパーパラメータ
γ, γ_0	G のディリクレ事前分布のパラメータ
\mathbf{R}^e	環境 e における位置分布の数
\mathbf{L}	場所概念の数
\mathbf{E}	ロボットがデータを収集した環境の数
\mathbf{T}	各環境においてデータの収集を実施した数

ただし、 $\mu^e, \Sigma^e, \pi^e, \mathbf{X}^e, r^e, C^e$ は、それぞれ環境 e における $\mu, \Sigma, \pi, x_t, r_t, C_t$ の集合、 $\phi^v, \phi^n, \mathbf{V}, \mathbf{N}, \mathbf{G}$ は、それぞれ $\phi^v, \phi^n, v_t, n_t, G$ の全体集合を表す。 C_l^e は環境 e において、 C_t は全環境において、 $C_t = l$ となる C_t の集合を表す。 $\mu_{n_k}, \kappa_{n_k}, \Psi_{n_k}, \nu_{n_k}, \beta_{new}, \gamma_{new}, \alpha_{new}^v, \alpha_{new}^n, \gamma_{0,new}$ は、それぞれ事後パラメータを表す。

3. 実験

複数のトレーニング用環境で収集されたマルチモーダル情報を用いて事前に場所概念を形成し、形成した場所概念をテスト用環境の場所概念形成に転移する。この時、テスト用環境では、ユーザからの名前の教示はデータに対して 0% から 21% しか与えられない。これにより、ユーザからの少ない教示のみでロボットが場所の名前や位置を予測する性能を評価する。

3.1 データ取得方法及びデータ取得環境

データの取得は、クラウド仮想環境である SIGVerse を用いて、ロボットを被験者が操作し、画像と自己位置の取得する。場所の名前は、テキストインプットにより与えた。

データの取得を行った環境としては、4 種類の間取り (1DK, 1LDK, 2LDK, 3LDK) を各 10 環境ずつ、合計 40 環境を準備した。各間取りにおいて、8 環境をトレーニング用、1 環境をバリデーション用、1 環境をテスト用とした。各環境では、形状やテクスチャが類似する物体が異なるレイアウトで配置されている。

3.2 場所概念の転移学習モデルの設定

画像情報と場所の名前情報のディリクレ事前分布のハイパーパラメータは $\alpha_v = 1, \alpha_n = 0.01$ とした。位置分布の事前分布であるガウス・逆ウィシャート分布のハイパーパラメータは $\kappa_0 = 0.03, \Psi_0 = \text{diag}[0.05, 0.05, 5, 5], \nu_0 = 5$ とし、 μ_0 は各環境の中心座標とした。多項分布 G のディリクレ事前分布

*1 ILSVRC2012: <http://www.image-net.org/challenges/LSVRC/2012/>

のハイパーパラメータは $\gamma = 10, \gamma_0 = 10$ とした. 多項分布 π のディリクレ事前分布のハイパーパラメータは $\beta = 0.06$ とした. 画像情報と場所の名前情報のインクリメントパラメータは $S_v = 1, S_n = 5$ とした. ギブスサンプリングのイテレーションは 100 とした.

3.3 名前予測実験

3.3.1 実験目的

場所概念転移学習モデルがトレーニング用環境で形成した場所概念をもとに, テスト用環境において場所の名前の教示回数が少ない場合でも, 自己位置と画像情報から概念を通して場所の名前を予測できるかを検証する.

3.3.2 実験条件

名前予測実験では, 新規環境においてどの程度名前を付与することで有効に名前予測ができるのかを確認するため, テスト用環境の名前情報の付与率を 0%, 7%, 14%, 21% と変化させ学習を行う. 各名前の付与率に対して, 事前に 0 環境, 2 環境, 4 環境, 8 環境, 16 環境, 32 環境のトレーニング環境で学習した場所概念転移学習モデルのほか, non-parametric Bayesian spatial concept acquisition method (SpCoA) [Taniguchi 16] を用いて名前予測結果の比較を行う.

3.3.3 名前の予測方法

テスト用環境 e において観測された画像情報 v_i^e と推定された自己位置情報 x_i^e から場所の名前情報 n_i^e を以下のように予測する. このとき, 確率 $p(n_i^e | x_i^e, v_i^e)$ が最も高くなる名前を予測した名前とする.

$$p(n_i^e | x_i^e, v_i^e) \propto \left\{ \sum_{C_i^e} p(n_i^e | C_i^e) p(C_i^e | x_i^e, v_i^e) \right\} \times I(n_i^e; C_i^e | \Theta) \quad (17)$$

$$\propto \left\{ \sum_{C_i^e} p(n_i^e | C_i^e) p(x_i^e, v_i^e | C_i^e) p(C_i^e | G^e) \right\} \times I(n_i^e; C_i^e | \Theta) \quad (18)$$

$$= \left\{ \sum_{C_i^e} \sum_{r_i^e} p(n_i^e | C_i^e) p(v_i^e | C_i^e) p(C_i^e | G^e) \times p(x_i^e | r_i^e) p(r_i^e | C_i^e) \right\} \times I(n_i^e; C_i^e | \Theta) \quad (19)$$

$$= \left\{ \sum_{C_i^e} \sum_{r_i^e} p(n_i^e | \phi_{C_i^e}^n) p(v_i^e | \phi_{C_i^e}^v) p(C_i^e | G^e) \times p(x_i^e | \mu_{r_i^e}, \Sigma_{r_i^e}) p(r_i^e | \pi_{C_i^e}^e) \right\} \times I(n_i^e; C_i^e | \Theta) \quad (20)$$

ただし, $I(n_i^e; C_i^e | \Theta)$ は場所の名前と場所概念のインデックスの相互情報量を表し, Θ は学習されたパラメータの集合 $\Theta = \{\mu^e, \Sigma^e, \pi^e, r^e, G^e, \phi^v, \phi^n, G_0\}$ を表す.

3.3.4 評価方法

場所の名前の予測結果は κ 係数を用いて評価する. κ 係数は, -1 から 1 の範囲で値をとり, 1 に近い値ほど予測した名前と正解ラベルの名前との一致度が高いことを示す評価指標である. Landis らが示した κ 係数の目安では, 0 未満が不一致 (poor), 0 以上 0.2 未満がごく軽度の一致 (slight), 0.2 以上 0.4 未満が軽度の一致 (fair), 0.4 以上 0.6 未満が中程度の一致 (moderate), 0.6 以上 0.8 未満が高度の一致 (substantial), 0.8 以上がほぼ

表 2: 名前予測の評価値の結果

	0%	7%	14%	21%
SpCoA	-0.03	0.19	0.30	0.29
転移学習モデル (0 環境)	0.02	0.39	0.39	0.51
転移学習モデル (2 環境)	0.65	0.61	0.70	0.71
転移学習モデル (4 環境)	0.77	0.72	0.74	0.78
転移学習モデル (8 環境)	0.76	0.79	0.71	0.81
転移学習モデル (16 環境)	0.83	0.86	0.88	0.85
転移学習モデル (32 環境)	0.95	0.94	0.93	0.94

完全な一致 (almost perfect) となっている [Landis 77].

$$\kappa = \frac{p_o - p_e}{1 - p_e} \quad (21)$$

$$p_o = \frac{c}{N} \quad (22)$$

$$p_e = \frac{1}{N^2} \sum_{k=1}^N n_k^{est} n_k^* \quad (23)$$

このとき, c は予測した場所の名前と正解ラベルの場所の名前が一致する数, N はテストデータの総数, n_k^{est} は予測した名前のうち名前辞書における k 番目の語彙と一致する数, n_k^* は正解ラベルの名前のうち名前辞書における k 番目の語彙と一致する数を表す.

4 種類の間取りのテスト用環境における κ 係数の平均値を名前予測の評価値とする. ここで, 被験者がテストデータに対して付与した場所の名前を正解ラベルの名前とする. つまり, 評価値が高いほどモデルが被験者に近い名前の予測ができていた事を意味している.

3.3.5 結果

表 2 に名前予測の評価値の結果を示す. 場所概念転移学習モデルは, 全ての名前の付与率において既存手法である SpCoA より高い数値になった. また, 場所概念転移学習モデルはトレーニング用環境の数が多いほど, 各名前の付与率において高い数値になる傾向があることが確認された.

3.4 位置予測実験

3.4.1 実験目的

場所概念転移学習モデルがトレーニング用環境で形成した場所概念をもとに, テスト用環境において場所の名前の教示回数が少ない場合でも, 場所の名前から概念を通して位置を予測できるかを検証する.

3.4.2 実験条件

位置予測実験では, 名前予測実験と同様, テスト用環境の名前情報の付与率を 0%, 7%, 14%, 21% と変化させ学習を行う. 各名前の付与率に対して, 事前に 0 環境, 2 環境, 4 環境, 8 環境, 16 環境, 32 環境のトレーニング環境で学習した場所概念転移学習モデルのほか, SpCoA を用いて位置予測結果の比較を行う.

3.4.3 位置の予測方法

テスト用環境 e において与えられた場所の名前 n_i^e から場所の位置 $x_i^{e,est}$ を以下のように予測する. 予測する位置は場所の名前から予測された位置分布の中心座標 (平均ベクトル) と

表 3: 位置予測の評価値の結果

	0%	7%	14%	21%
SpCoA	4.33	4.43	3.76	3.07
転移学習モデル (0 環境)	4.26	2.62	3.32	2.75
転移学習モデル (2 環境)	2.31	2.05	1.59	1.70
転移学習モデル (4 環境)	2.07	1.27	1.99	1.47
転移学習モデル (8 環境)	1.41	1.78	2.07	1.56
転移学習モデル (16 環境)	1.29	1.79	1.30	1.29
転移学習モデル (32 環境)	1.21	1.22	1.43	1.49

する.

$$r_t^{e,est} = \operatorname{argmax}_{r_t^e} p(r_t^e | n_t^e) \quad (24)$$

$$= \operatorname{argmax}_{r_t^e} \sum_{C_t^e} p(r_t^e | C_t^e) p(C_t^e | n_t^e) \quad (25)$$

$$= \operatorname{argmax}_{r_t^e} \sum_{C_t^e} p(r_t^e | C_t^e) p(n_t^e | \phi_{C_t^e}^n) p(C_t^e | G^e) \quad (26)$$

$$= \operatorname{argmax}_{r_t^e} \sum_{C_t^e} p(r_t^e | \pi_{C_t^e}) p(n_t^e | \phi_{C_t^e}^n) p(C_t^e | G^e) \quad (27)$$

$$x_t^{e,est} = \mu_{r_t^{e,est}} \quad (28)$$

3.4.4 評価方法

被験者が場所の名前を教示した位置を x_t^* として、その位置と推定した位置 $x_t^{e,est}$ との誤差を以下のように計算し、 $cost_t$ と定義する。また、全てのテストデータの誤差の平均値を $cost^{ave}$ とし、評価値とする。評価値は低い数値であるほど、予測できていることを示す。

$$cost_t = \sqrt{(x_t^* - x_t^{e,est})^2 + (y_t^* - y_t^{e,est})^2} \quad (29)$$

$$cost^{ave} = \frac{1}{N} \sum_{t=1}^N cost_t \quad (30)$$

ただし、 N はテストデータの総数を表す。

1DK, 1LDK のテスト用環境における $cost^{ave}$ の平均値を位置予測の評価値とする。このとき、2LDK, 3LDK のテスト用環境は同じ名前が複数存在するため評価の対象としない。位置予測の評価値が低いほど、モデルが被験者に近い場所の位置を予測できている事を意味している。

3.4.5 結果

表 3 に位置予測の評価値の結果を示す。場所概念転移学習モデルはトレーニング用環境の数が多いほど数値は低くなる傾向があり、既存手法である SpCoA よりも数値が低くなる事が確認された。また、場所概念転移学習モデルは、データに対する名前の付与が行われない 0% の結果においても高い精度で位置の予測ができている事が確認された。

4. おわりに

本研究では、クラウド仮想環境を用いた場所概念転移学習モデルによる大規模な性能評価実験を場所の名前と位置の予測において実施した。

今回実施した名前予測実験及び位置予測実験より、大規模な環境で学習した場所概念転移学習モデルは名前の教示回数が少

ない場合でも、既知の環境で形成された場所概念を新規環境に転移する事により、新規環境においてユーザの認識に近い場所の名前や位置が予測できることが示された。

今回実施した実験で用いたトレーニング用環境とテスト用環境では、類似した形状やテクスチャの物体が配置されていた。そのため、場所概念転移学習モデルを用いた場合、テスト用環境に場所概念の転移が行われやすく、名前予測や位置予測の性能が高かったと考えられる。今後の展望として、各環境に配置された物体の形状やテクスチャが異なる場合や複数の被験者を対象とした実験条件での評価や提案モデルの拡張を行っている。

参考文献

- [Kostavelis 13] Kostavelis, Ioannis, and Antonios Gasteratos. "Learning spatially semantic representations for cognitive robot navigation." *Robotics and Autonomous Systems* 61.12 (2013): 1460-1475.
- [Taniguchi 16] Taniguchi, Akira, Tadahiro Taniguchi, and Tetsunari Inamura. "Spatial concept acquisition for a mobile robot that integrates self-localization and unsupervised word discovery from spoken sentences." *IEEE Transactions on Cognitive and Developmental Systems* 8.4 (2016): 285-297.
- [Ishibushi 16a] Ishibushi, Satoshi, et al. "Statistical localization exploiting convolutional neural network for an autonomous vehicle." *Industrial Electronics Society, IECON 2015-41st Annual Conference of the IEEE. IEEE, 2015.*
- [Ishibushi 16b] 石 伏 智 . "Transfer Learning." <https://youtu.be/bK77nOKYGW4>. (2017)
- [Inamura 10] Inamura, Tetsunari, et al. "Simulator platform that enables social interaction simulation—SIGVerse: SocioIntelliGenesis simulator." *System Integration (SII), 2010 IEEE/SICE International Symposium on. IEEE, 2010.*
- [Asada 16] 浅田和弥, 萩原良信, 谷口忠大, 稲邑哲也: 「没入型インタフェースを伴うクラウド仮想環境における HRI に基づく場所の学習」 *インタラクシオン 2017 年 3 月, 東京, 2-501-10.*
- [Jia 14] Jia, Yangqing, et al. "Caffe: Convolutional architecture for fast feature embedding." *Proceedings of the 22nd ACM international conference on Multimedia. ACM, 2014.*
- [Landis 77] Landis, J. Richard, and Gary G. Koch. "An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers." *Biometrics* (1977): 363-374.