

Robotyczne uczenie transferu kontaktów

Marek Kopicki

School of Computer Science, University of Birmingham, UK

Email: msk@cs.bham.ac.uk

Streszczenie—Wykład będzie dotyczył uczenia transferu kontaktów pomiędzy robotem a otoczeniem dla robotów w pełni sterowanych i niedosterowanych o dowolnej liczbie stopni swobody. Otoczenie jest modelowane za pomocą sensora RGB-D, z jednego bądź więcej widoków. Prezentowana metoda jest w stanie przewidzieć np. chwyt nowego obiektu przez robota na podstawie nawet jednego przykładu. Metoda wykorzystuje iloczyn modeli generatywnych reprezentowanych przez rozkłady prawdopodobieństwa reprezentujące kontakty pomiędzy członami robota a otoczeniem oraz rozkład reprezentujący konfigurację robota specyficzną np. dla danego typu chwytu. W ramach wykładu przedstawione zostaną wyniki eksperymentalne potwierdzające efektywność metody dla różnych typów chwytaków, a także jej potencjalne praktyczne zastosowania.

I. WPROWADZENIE

Problem chwytania obiektów przez roboty jest modelowym przykładem zastosowania metody uczenia transferu kontaktów. Istnieją dwie ogólne kategorie algorytmów uczących do chwytania obiektów. Pierwsza kategoria rozpatruje kształt i wygląd lokalnej części obiektu z obrazu RGB-D [1, 2, 6], bądź RGB [9], również wykorzystując Deep Learning [7, 8]. Najważniejszą zaletą tej grupy algorytmów jest wydajna generalizacja chwytów dla nowych obiektów. Natomiast jej podstawowym ograniczeniem jest uproszczony model dłoni (zazwyczaj prosty równoległy chwytak), jak również duża liczba wymaganych przykładów uczących. Druga kategoria rozpatruje dłonie z dużą liczbą stopni swobody i typowo rozwiązuje transfer chwytów poprzez połączenie kształtu dłoni z kształtem obiektu [3]. Podstawowym problemem metod tej kategorii są ograniczone możliwości transferu dla obiektów o różnym (globalnym) kształcie.

Prezentowana metoda nie tylko łączy najlepsze cechy dwóch powyższych kategorii, jak również umożliwia wydajny transfer kontaktów nawet na podstawie jednego przykładu. Ponadto metoda umożliwia stosowanie różnych wizualnych reprezentacji takich jak krzywizny powierzchni, wielopoziomowe hierarchie części, bądź CNNs.

II. ALGORYTM

Metoda opiera się na uczeniu dwóch typów modeli reprezentowanych przez rozkłady (Rys. 2 i Rys. 4). Model kontaktu reprezentuje kontakt pomiędzy poszczególnym członem robota a otoczeniem (obiektem treningowym). Ilość modeli kontaktów może być różna dla różnych typów chwytu. Model konfiguracji reprezentuje podprzestrzeń możliwych konfiguracji robota specyficznych dla danego typu chwytu.


Nowy chwyt jest generowany na podstawie nowej chmury punktów uzyskanej z sensora RGB-D, oraz na podstawie



Rysunek 1: Cztery obiekty użyte do uczenia pięciu chwytów oraz 43 obiekty użyte do testów transferu chwytów (po lewej stronie). Robot Borys (na prawo).

dwóch typów powyższych modeli. Rozkład zapytania jest konstruowany dla każdego modelu kontaktu i nowej chmury punktów. Rozkład zapytania jest to model generatywny reprezentujący możliwe położenia i orientacje danego człona robota w zależności od "lokalnego" podobieństwa danego kontaktu, ale niezależnie od innych kontaktów (Rys. 3). Każdy transfer chwytu wymaga równoczesnego spełnienia niezależnych ograniczeń w postaci kontaktu człona-otoczenie. Problem transferu kontaktów został przedstawiony jako zadanie maksymalizacji iloczynu wszystkich rozkładów zapytania razem z modelem konfiguracji reprezentującym wzajemne relacje pomiędzy kontaktami.


Powyższa procedura maksymalizacji iloczynu rozkładów poszukuje położenia i orientacji dłoni robota, jak i jej konfiguracji w zależności od możliwych typów chwytów. Takich rozwiązań może być wiele, dlatego cała procedura jest następnym modelem generatywnym generującym lokalnie optymalne chwytaki (układy kontaktów). Przy chwytaniu obiektów dłonią




Rysunek 3: Rozkład zapytania (czerwony) dla dwóch modeli kontaktów/członów (niebieski).




Rysunek 2: Uczenie modeli kontaktów i konfiguracji (lewo) oraz transfer chwytów dla nowej chmury/obiektu (prawo).



Rysunek 4: Uczenie chwytów (lewo) i transfer dla nowej chmury punktów: selekcja (środek) i wykonanie (prawo).



Rysunek 5: Uczenie chwytów dla robota niedosterowanego.



Rysunek 6: Przykład wstawiania naczyń do ociekacza. Na lewo: Rozkład reprezentujący kontakt naczynie-ociekacz (czerwony) i trajektorię naczynia (zielony). Na prawo: optymalna trajektoria obliczona z iloczynu tych rozkładów.

o 20 stopniach swobody i dla 5 typów chwytów uzyskaliśmy 77.7% i 84.4% udanych chwytów dla odpowiednio jednego i wielu widoków sensora RGB-D [5]. Wynik 84.4% może zostać poprawiony do 95.6% po wykonaniu następnego typu chwytu przez robota.

III. ROZSZERZENIA

Metoda uczenia transferu kontaktów może zostać zastosowana w wielu innych sytuacjach. Obecnie z powodzeniem testujemy ją z Pisa Soft Hand, robota niedosterowanego o 19 stopniach swobody (Rys. 5), także do transferu całych trajektorii kontaktów. Metoda może być również wykorzystana do uczenia relacji pomiędzy obiektami, np. podczas wstawiania naczyń do ociekacza (Rys. 6). Ponadto intensywnie pracujemy nad połączeniem z reprezentacjami wizualnymi opierającymi się na hierarchiach części i splotowych sieciach neuronowych. Metoda jest również w trakcie komercjalizacji [4].

LITERATURA

[1] R. Detry, C. Henrik Ek, M. Madry, and D. Kragic. Learning a dictionary of prototypical grasp-predicting parts from grasping experience. In *ICRA*, pages 601–608. IEEE, 2013.

[2] A. Herzog, Peter P. M. Kalakrishnan, L. Righetti, J. Bohg, T. Asfour, and S. Schaal. Learning of grasp selection based on shape-templates. *Autonomous Robots*, 36(1-2):51–65, 2014.

[3] U. Hillenbrand and M.A. Roa. Transferring functional grasps through contact warping and local replanning. In *IROS*, pages 2963–2970. IEEE, 2012.

[4] M. Kopicki. Grasp modelling, March 30 2016. URL <http://www.google.com/patents/EP2999575A1>. EP Patent App. EP20,140,726,730.

[5] M. Kopicki, R. Detry, M. Adjigble, R. Stolkin, A. Leonardis, and J. L. Wyatt. One shot learning and generation of dexterous grasps for novel objects. *The International Journal of Robotics Research*, 2015. doi: 10.1177/0278364915594244.

[6] O. Kroemer, E. Ugur, E. Oztop, and J. Peters. A kernel-based approach to direct action perception. In *ICRA*, pages 2605–2610. IEEE, 2012.

[7] I. Lenz, H. Lee, and A. Saxena. Deep learning for detecting robotic grasps. *The International Journal of Robotics Research*, 34(4-5):705–724, 2015.

[8] S. Levine, P. Pastor, A. Krizhevsky, and D. Quillen. Learning hand-eye coordination for robotic grasping with deep learning and large-scale data collection. *preprint arXiv:1603.02199*, 2016.

[9] A. Saxena, L. Wong, and A.Y. Ng. Learning grasp strategies with partial shape information. In *Proceedings of AAAI*, pages 1491–1494. AAAI, 2008.