

Preensão Robótica - Abordagens, Dificuldades da Área e Avanços Futuros^{*}

Kleber L. S. Filho^{*} Leizer Schmitman^{**} Sérgio R. X. Silva^{***}

^{*} PPGM - Programa de Pós-Graduação em Mecatrônica, UFBA - Universidade Federal da Bahia, Salvador, Bahia, Brasil. E-mail: engkleberf@gmail.com

^{**} PPGM - Programa de Pós-Graduação em Mecatrônica, Universidade Federal da Bahia, Salvador, Bahia, Brasil. E-mail: leizer@ufba.br

^{***} UNEB - Universidade do Estado da Bahia, Salvador, Bahia, Brasil. E-mail: srxsilva@uneb.br

Abstract: Over the years, the robot grasping area has received considerable attention. Several techniques were developed to increase the efficiency and autonomy of robot manipulators. This work presents a brief review and analysis of different techniques applied to deep learning-based robot grasping generation models, in addition to some of the challenges that need to be overcome in the area.

Resumo: Ao longo dos anos, a área de preensão de robôs recebeu atenção considerável. Diversas técnicas foram desenvolvidas para aumentar a eficiência e autonomia dos robôs manipuladores. Este trabalho apresenta uma breve revisão e análise de diferentes técnicas aplicadas a modelos de geração de preensões robóticas baseados em aprendizagem profunda, além de alguns dos desafios que precisam ser superados na área.

Keywords: Robot grasping, object manipulation, deep learning, reinforcement learning, artificial intelligence.

Palavras-chaves: Preensão robótica, manipulação de objetos, aprendizagem profunda, aprendizagem por reforço, inteligência artificial.

1. INTRODUÇÃO

A melhoria nas capacidades de interação e modificação de forma autônoma, busca a tornar o desenvolvimento de tarefas por meio de robôs manipuladores progressivamente mais eficiente e seguro, algo que pode favorecer diversas áreas, como: indústria, plataformas de petróleo, organização de estoques, reabilitação, entre outras.

Ao longo das últimas décadas o estudo da manipulação de objetos por robôs, associado à recente utilização de modelos de aprendizagem de máquina, proporcionou diversos avanços na área, tornando a sua interação com os ambientes de trabalho cada vez mais autônoma.

O ato de agarrar e suspender objetos por meio de um efetuador final, sem que ocorra escorregamento, recebe na literatura o nome de preensão robótica. Por muito tempo o desenvolvimento de preensões esteve diretamente associado ao controle de parâmetros relacionados às posições e forças aplicadas por meio da garra. Durante a execução da preensão, os algoritmos responsáveis pela geração de preensões dependiam de modelos matemáticos que levassem em conta propriedades como: resistência a perturbações em qualquer direção, mobilidade do objeto, equilíbrio de forças e estabilidade (Shimoga, 1996; Roa e Suárez, 2015).

^{*} Os autores agradecem à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) e à FAPESB (Fundação de Amparo à Pesquisa do Estado da Bahia) pelo apoio financeiro.

Para a geração de preensões se fazia necessário que o programador se baseasse no conhecimento prévio de diversos parâmetros referentes ao objeto, manipulador, volume de trabalho e as mudanças às quais os mesmos pudessem ser futuramente submetidos. Por esse motivo a abordagem analítica era essencialmente dependente da intervenção humana.

As abordagens empíricas para a preensão robótica, por sua vez, se baseiam na utilização de métodos de classificação e aprendizagem de máquina para efetuar a manipulação do objeto, desta forma evitando a complexidade matemática requerida na utilização dos métodos baseados em abordagens analíticas. Porém, assim como aponta Bohg et al. (2013), nesse tipo de abordagem, propriedades como: destreza, equilíbrio ou estabilidade na geração de preensões; apenas podem ser verificadas empiricamente. Por dependerem de experiências anteriores bem sucedidas, metodologias baseadas em abordagens empíricas costumam assumir que todos os parâmetros necessários para o desenvolvimento da tarefa são conhecidos, resultando na incapacidade de generalização em relação a objetos desconhecidos pelo manipulador (Caldera et al., 2018; Morrison et al., 2018, 2019)

Em ambientes estruturados, onde se têm total controle da posição, orientação e geometria dos objetos inseridos no volume de trabalho, abordagens clássicas de preensão robótica podem ser aplicáveis sem a necessidade da introdução de modelos baseados em aprendizagem profunda.

Entretanto tais exigências limitam o número de aplicações às quais os algoritmos de prensão podem ser empregados, uma vez que no mundo real é comum a necessidade de lidar com ambientes dinâmicos e na grande maioria das vezes não estruturados, isto é, nos quais o sistema não tem conhecimento de todos os parâmetros atrelados à tarefa que deve ser desenvolvida.

Com a utilização de modelos de aprendizagem de máquina baseados em aprendizagem profunda, os parâmetros associados às tarefas, que outrora requeriam extensos cálculos e intervenções humanas, podem ser aprendidos de forma intrínseca. Para isso, assim como em outras aplicações, os modelos são submetidos ao processo de treinamento, seja este a partir de dados obtidos por meio de bases públicas ou privadas, no caso de modelos supervisionados, ou a partir de experiências no estilo tentativa e erro, ao se utilizar, por exemplo, estratégias baseadas em aprendizagem por reforço.

O presente trabalho apresenta um histórico e contextualização acerca de técnicas distintas para a geração de prensões por modelos baseados em aprendizagem profunda. O texto está organizado da seguinte forma: a Seção 2 explora as diferenças entre modelos de aprendizagem supervisionada e aprendizagem por reforço no contexto de prensão robótica; a Seção 3 apresenta um resumo de um conjunto de abordagens divididas com base na quantidade de modelos necessários para geração de prensões; a Seção 4 apresenta exemplos de ramos de pesquisas baseados na geração de prensões robóticas e seus desafios, sendo discutidas, por exemplo, prensões do tipo 6-DoF, além de prensões seletivas e semânticas; por fim a Seção 5 traz a conclusão e uma breve discussão do trabalho.

2. MODELOS DE GERAÇÃO DE PRENSÃO

O surgimento de trabalhos como os de Lenz et al. (2015); Mahler et al. (2016); Pinto e Gupta (2016); Levine et al. (2016); Morrison et al. (2018), os quais empregam modelos baseados em aprendizagem profunda, representou um grande marco na área de prensão robótica. Diferindo das abordagens clássicas, os modelos de prensão baseados em aprendizagem profunda demonstraram uma capacidade conveniente de generalização, isto é, permitir a geração de prensões em uma vasta gama de objetos que fossem desconhecidos por parte do modelo computacional ou do programador. Além disso, também possibilitaram a geração de prensões de maneira mais eficiente e com uma redução considerável da necessidade da interação humana sem que fossem necessários extensos cálculos.

Na literatura, os modelos utilizados para a geração de prensões robóticas baseados em aprendizagem profunda são treinados quase predominantemente por meio de aprendizagem supervisionada (Morrison et al., 2019; Huang et al., 2020; Breyer et al., 2021) e aprendizagem por reforço (Mahler et al., 2016; Kalashnikov et al., 2018; Sun et al., 2020; Sundermeyer et al., 2021; Danielczuk et al., 2021).

2.1 Aprendizagem Supervisionada

Na aprendizagem supervisionada um modelo computacional é treinado a partir de exemplos rotulados contidos em uma base de dados. Durante o treinamento os exemplos

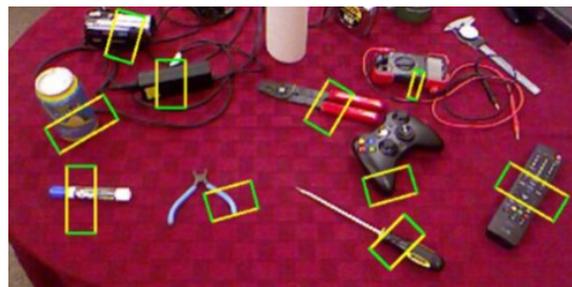


Figura 1. Representação de possíveis prensões indicadas pelos retângulos sugeridos por Lenz et al. (2015). As linhas verdes indicam a posição das garras paralelas antes do fechamento e consequente prensão (Lenz et al., 2015)

rotulados são utilizados para "ensinar" o modelo a como agir quando, no momento de inferência, for apresentado a novos dados ainda não rotulados. Goodfellow et al. (2016) resumem o processo da seguinte forma: os modelos supervisionados recebem exemplos de observações x , acompanhadas de rótulos y , e devem, ao longo do treinamento, aprender a inferir y a partir de x .

No contexto de prensão robótica, os parâmetros necessários para a execução da manipulação são geralmente introduzidos em vetores, os quais são comumente conhecidos como representações de prensão. No modelo de Lenz et al. (2015), cada prensão possível é parametrizada como um retângulo na imagem obtida pela câmera, regido por um vetor de 5 dimensões que inclui sua posição de acordo com o eixo X e Y, orientação angular com base na imagem, altura e largura do retângulo (Figura 1). De forma semelhante, Wang et al. (2016) adotam uma representação de prensão que integra a localização da prensão no plano da mesa (x, y) , abertura da garra e ângulo de orientação. A representação de prensão escolhida por Pinto e Gupta (2016) é relativamente mais simples, possuindo apenas a posição planar e orientação da garra. Mesmo existindo uma tendência para a utilização de representações mais simples, representações similares a de Lenz et al. (2015) podem ser encontradas em trabalhos mais recentes, a exemplo de Sun e Gao (2021).

Para aprender a inferir representações de prensão, normalmente os modelos são expostos a exemplos diferentes de imagens de objetos contidos em uma bases de dados. Cada imagem costuma incluir retângulos parametrizados com base nas representações de prensão. Para a comparação das prensões inferidas pelo modelo com aquelas provenientes da base de dados, são adotadas métricas que comparem o nível de sobreposição entre um retângulo construído com base nos parâmetros de prensão inferidos e os retângulos da imagem rotulada (Lenz et al., 2015; Redmon e Angelova, 2015; Morrison et al., 2018).

Assim como apontam Caldera et al. (2018) grande parte dos modelos supervisionados encontrados na literatura exigem o uso de bases relativamente grandes de dados rotulados. A criação de bases de dados do tipo costuma ser extremamente laboriosa, dependendo frequentemente da intervenção humana (Caldera et al., 2018; Pinto e Gupta, 2016; Levine et al., 2016; Mahler et al., 2017). Devido ao fato de abordagens baseadas em aprendizagem por reforço

dependem de pouca ou nenhuma intervenção humana, existem também na literatura trabalhos que tornam a tarefa de rotulagem de dados um processo autônomo, algo explorado em pesquisas como as de Pinto e Gupta (2016); Mahler et al. (2019); Sun e Gao (2021). Dessa forma, esses trabalhos possibilitam a criação autônoma de bases de dados com dimensões relativamente maiores do que aquelas que dependem da rotulagem humana.

Algumas das opções de bases de dados específicas para a prensão robótica são: *Cornell Dataset* (Lenz et al., 2015), *Jacquard Dataset* (Depierre et al., 2018), o *Grasping Dataset* de (Levine et al., 2016), *Dex-Net* (em suas diversas versões) (Mahler et al., 2016, 2017, 2018, 2019), e o *EGAD!* (Morrison et al., 2020).

2.2 Aprendizagem por Reforço

Os algoritmos de aprendizagem por reforço utilizam uma entidade denominada agente para interagir com o ambiente. As informações atuais do ambiente são passadas para o agente por meio dos chamados estados. Com base nos estados o agente deve executar ações que o possibilitem alcançar objetivos específicos. A tomada de decisões é responsabilidade da política, que representa a estratégia que será seguida com base no estado atual em que o agente se encontra. Ações adequadas devem receber as denominadas recompensas, geralmente representadas por valores. Dessa forma a política considerada "ótima" é aquela que maximiza o somatório de recompensas obtidas ao longo das iterações (retorno).

Para calcular o retorno obtido a longo prazo, ao se adotar uma política π , são utilizadas primariamente duas funções principais, Valor e Valor da Ação(Q). A função Valor é utilizada para indicar o quão vantajoso é estar em um estado específico, regido por π e tomando como base o retorno. A função Q é similar, porém nesse caso se considera o retorno que será obtido ao se adotar uma ação específica no estado atual e seguindo-se a política π nos próximos estados. Para maximizar o retorno a longo prazo, deve-se então adotar para o estado S a ação que resultará no maior valor da função Q.

Mahler et al. (2016) utilizam uma abordagem baseada na estratégia *multi-armed bandits* para a realização de prensões. O algoritmo *Dex-Net*, assim como especificado pelos autores, tem como objetivo otimizar a probabilidade de sucesso de prensões que atendam ao requisito de *force-closure* (prensões capazes de resistir a forças aplicadas externamente). Em Mahler et al. (2017), além de uma segunda base de dados, denominada *Dex-Net 2.0* é apresentado um planejador de prensões treinado com base no método de entropia cruzada para aprendizagem por reforço, seguido por um modelo de rede neural convolucional (CNN), que recebeu o nome de *Grasp Quality CNN* (GQ-CNN) para avaliar as prensões candidatas de forma a garantir que são alcançáveis pelo manipulador e não causarão colisão com a mesa. Em Mahler et al. (2018, 2019) foram desenvolvidas duas novas versões dos planejadores de prensão e da GQ-CNN. Em Mahler et al. (2018) é gerada uma política responsável por gerar prensões por sucção, enquanto em Mahler et al. (2019) o modelo aprende uma política capaz de alternar entre a utilização

de uma garra de sucção e uma garra de dedos paralelos com base na probabilidade de sucesso, dado o objeto alvo.

Existem ainda trabalhos como Pinto e Gupta (2017); Zeng et al. (2018); Guo et al. (2019); Sun et al. (2020) que exploram as capacidades dos modelos de aprendizagem por reforço para gerar ações que possam auxiliar uma futura prensão. Zeng et al. (2018), por exemplo, utiliza duas redes CNN em conjunto para o aprendizado de uma política que combina o ato de empurrar e agarrar objetos com base em observações visuais. O modelo é treinado de maneira fim-a-fim utilizando *Deep Q-learning*, gerando valores Q com base em possíveis ações de empurrar ou agarrar objetos.

Para facilitar uma futura prensão, Sun et al. (2020) treinam uma política que é capaz de empurrar objetos contra uma parede utilizando um algoritmo baseado em *Soft-Actor-Critic*. O sistema consiste de dois manipuladores robóticos, um responsável por gerar a prensão e outro responsável por facilitá-la empurrando os objetos contra uma parede quando necessário, de forma a mudá-los de uma posição em que não seria possível realizar uma prensão para uma posição em que essa seja possível.

3. ESTRATÉGIAS PARA A GERAÇÃO DE PRENSÃO

3.1 Geração e refinamento de candidatas

Uma estratégia comum, especialmente nos primeiros trabalhos, foi a de empregar sistemas de geração de múltiplas amostras de prensões (candidatas), associados a sistemas de refinamento, os quais deveriam eleger aquelas com maiores probabilidades de sucesso. O trabalho de Lenz et al. (2015), por exemplo, representa uma das primeiras abordagens a empregar modelos de aprendizagem profunda para a geração de prensões planares do tipo *top-down*, isto é, prensões em que a garra adota uma configuração fixa apontada para baixo, sendo apenas capaz de agarrar objetos de cima para baixo. Nesse caso alterações na orientação do efetuador final estão limitadas à rotação em relação ao eixo ortogonal à mesa. O sistema utiliza duas redes neurais convolucionais ou CNN, a primeira responsável por gerar prensões candidatas e a segunda por executar o refinamento. A segunda rede possui um número relativamente maior de parâmetros treináveis do que a primeira a segunda, porém limita-se apenas à análise do conjunto pré-selecionado de prensões candidatas. O sistema é totalmente treinado de maneira supervisionada.

Outro exemplo é o trabalho de Wang et al. (2016), o qual divide a geração de prensões em 3 estágios. O primeiro estágio segmenta e discrimina objetos que permitem a manipulação. O segundo estágio gera prensões candidatas apenas nos objetos manipuláveis, enquanto o terceiro estágio realiza o refinamento das prensões. Assim como no trabalho de Lenz et al. (2015), utilizam uma estratégia de treinamento supervisionado.

Seguindo uma estratégia um pouco diferente das anteriores, em vez da geração de prensões candidatas, a primeira etapa do sistema de Levine et al. (2016) é responsável pela geração direta de amostras dos possíveis movimentos que o manipulador robótico pode efetuar, seguida por uma rede

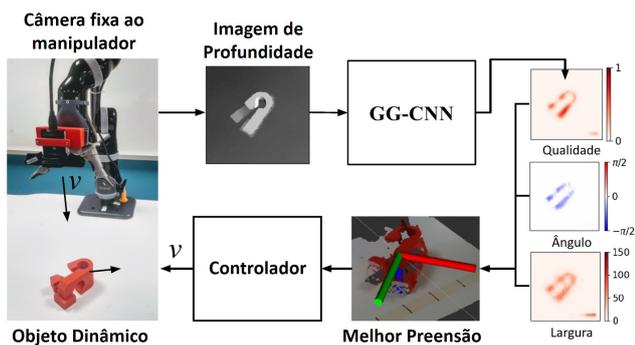


Figura 2. Diagrama de representação da segmentação de instruções da GGCNN - Adaptado de Morrison et al. (2018)

CNN que seleciona aquele que possui maior probabilidade de culminar na aproximação entre o efetuador final e algum dos objetos. Além disso, o sistema avalia de forma iterativa se o movimento escolhido pode resultar em uma preensão bem sucedida. Quando existe uma alta probabilidade de sucesso o sistema solicita o fechamento da garra, em caso negativo a garra é reposicionada e ocorre a execução e avaliação de novas ações. A CNN recebe como entrada uma imagem RGB-D que observa o efetuador final e os objetos no volume de trabalho, a partir de uma câmera colocada em uma posição fixa. Os autores se referem à abordagem como *hand-eye coordination* (HEC), em tradução livre coordenação mão-olho.

Outros sistemas mais atuais podem também utilizar estratégias de geração e refinamento de preensões por meio de modelos especializados para garantir habilidades importantes em aplicações específicas, como: a prevenção contra colisões (Mousavian et al., 2019; Ichnowski et al., 2020; Murali et al., 2020a), ou a manipulação e utilização de ferramentas (Antanas et al., 2019; Liu et al., 2020; Sun e Gao, 2021).

Por dependerem de uma ou mais etapas de geração, seguidas por uma etapa de refinamento, o número de parâmetro treináveis dos sistemas aqui tratados costuma ser relativamente grande, por consequência, modelos que seguem essa estratégia podem sofrer longos tempos de treinamento e inferência. Por esse motivo, Zhu et al. (2022) consideram a função de geração de preensões planares como sendo equivariante em $SE(2)$, sugerindo que rotações ou translações sofridas pelas imagens de entrada devem resultar nas mesmas rotações e translações no momento de preensão. O modelo treinado a partir de aprendizagem por reforço, mais especificamente utilizando um algoritmo com base na estratégia de *contextual bandits*, precisou de menos de 600 iterações para aprender a realizar preensões planares em objetos selecionados (preensão seletiva).

3.2 Sistemas one-shot

Alguns autores optam pela utilização de abordagens que empreguem modelos do tipo *one-shot*, isto é, quando um único modelo é capaz de detectar preensões de uma só vez, e não depende da divisão das tarefas de geração de preensões candidatas e refinamento (Redmon e Angelova, 2015; Pinto e Gupta, 2016; Viereck et al., 2017; Redmon

e Angelova, 2015; Kumra e Kanan, 2017; Morrison et al., 2018; Kalashnikov et al., 2018).

O modelo *one-shot* de Pinto e Gupta (2016) se inspira em aprendizado por reforço (*reinforcement learning*), sendo capaz de aprender a gerar preensões em objetos a partir de tentativa e erro. Uma base de dados é gerada com base nas tentativas anteriores, e os dados são utilizados para treinar um modelo supervisionado baseado em CNN, o qual será responsável pela geração de novas preensões.

Viereck et al. (2017) se inspiram na abordagem HEC de Levine et al. (2016), desenvolvendo um sistema que gera e avalia possíveis ações baseadas na localização planar do efetuador em relação aos objetos. A câmera utilizada pelos autores é agora fixada ao manipulador robótico. O sistema foi inteiramente treinado a partir de simulações. A CNN recebe como entrada a camada de profundidade da câmera RGB-D, as posições planares e orientação da garra. Os autores executam testes de preensão em objetos que podem ser dispensados de forma individual na área de trabalho ou em conjunto de forma aglomerada e desordenada. Adicionalmente para este último caso, também avaliam a capacidade da rede em lidar com o aglomerado de objetos em movimento.

Visando o desenvolvimento de modelos que sejam capazes de lidar com ambientes dinâmicos em tempo real, Morrison et al. (2018) considera cada pixel em uma imagem como um possível ponto de preensão, atribuindo parâmetros de preensão e um valor que indique a probabilidade de sucesso a cada um desses. O modelo de Morrison et al. (2018), denominado GGCNN (*Generative Grasping CNN*), recebe como entrada apenas uma imagem de profundidade adquirida por uma câmera RGB-D fixada ao manipulador. Utilizando camadas de convolução e convolução transposta, a rede produz como saída 3 diferentes imagens com as mesmas dimensões da entrada. Cada imagem de saída representa um mapa que corresponde às representações de qualidade da preensão (probabilidade de sucesso), largura de abertura da garra W e sua orientação Φ (Figura 2). Uma vez identificada a posição de maior qualidade de preensão estimada dentro da referida matriz, essa é adotada como ponto central da preensão. O sistema recorre então aos pixels de posição análoga nas outras duas matrizes para definir a orientação Φ e abertura da garra W .

4. EVOLUÇÕES NA ÁREA E DESAFIOS EM ABERTO

4.1 Preensão em 6 dimensões

Grande parte dos trabalhos desenvolvidos até o momento se concentram na execução de preensões planares, as quais, conforme sugerido anteriormente, não permitem mudanças de maneira tridimensional na orientação do efetuador final. É importante pontuar que a utilização de preensões planares, pode não só limitar as possibilidades de geração de preensões, como inviabilizar a adoção do sistema em diversas aplicações no mundo real, por exemplo: ao se trabalhar com aglomerados de objetos Murali et al. (2020b); Mohammed et al. (2020) ou quando se deseja obter objetos organizados em prateleiras Kleeberger et al. (2020); Huang et al. (2020).

Nos últimos anos, em contraste com a prensão planar, que apenas permitia uma orientação fixa, houve um crescimento nítido na exploração de modelos que permitam a geração de prensões a partir de diferentes orientações do efetuador final (Mousavian et al., 2019; Song et al., 2020; Murali et al., 2020b,a; Breyer et al., 2021; Wang et al., 2022b). Modelos desse tipo, costumam ser identificadas pelo termo 6-DoF, do inglês *Degrees of Freedom* (Graus de liberdade), uma vez que, a posição e orientação do efetuador final podem ser representados, respectivamente, a partir de translações e rotações em torno de 3 eixos distintos, cada uma.

No contexto de geração de prensões planares, existem trabalhos que optam por treinamentos com base apenas em imagens bidimensionais, porém, no caso de prensões 6-DoF, os modelos utilizam majoritariamente entradas com base em representações tridimensionais do volume de trabalho, de forma a garantir o ajuste da garra ao objeto e possibilitar a prevenção contra colisões, por exemplo.

Uma das abordagens mais comumente adotadas para representações tridimensionais tem como base a adoção de nuvens de pontos, conjuntos desordenados de pontos utilizados para ilustrar uma representação tridimensional do ambiente digitalizado. Porém, assim como apontam Guo et al. (2020), a utilização de nuvens de pontos como entradas para modelos baseados em aprendizagem profunda ainda enfrenta alguns desafios, como: o baixo número de bases de dados disponíveis, a alta dimensionalidade dos dados e a sua natureza desordenada. Por conta da sua natureza, modelos de aprendizagem profunda sofrem dificuldades para encontrar relações entre pontos que deveriam representar regiões vizinhas. Além disso, não existe uma distribuição ou densidade padrão em relação à quantidade de pontos em diferentes regiões, dificultando a aplicação de redes do tipo CNN comuns (Qi et al., 2017a).

Para mitigar os problemas descritos, existem na literatura diversas arquiteturas de aprendizagem de máquina desenvolvidas especialmente para lidar com nuvens de pontos, entre elas as de: Atzmon et al. (2018); Hua et al. (2018); Thomas et al. (2019). No contexto de prensões, porém, as arquiteturas mais comumente utilizadas se baseiam nos modelos denominados pointnet (Qi et al. (2017a)) e pointnet++ (Qi et al. (2017b)), a exemplo dos trabalhos de Murali et al. (2020b,a); Wang et al. (2022a); Mousavian et al. (2019); Danielczuk et al. (2021).

O sistema desenvolvido por Murali et al. (2020b) é capaz de gerar prensões 6-DoF, e pode ser dividido em 3 etapas. A primeira etapa consiste de um modelo de Autoencoder Variacional que gera amostras de prensão. A segunda etapa é responsável por avaliar e selecionar prensões que não se encontrem em colisão com outros objetos e possuam uma probabilidade maior que um limiar previamente definido. Os autores apontam que uma parte das prensões rejeitadas podem ser facilmente melhoradas a partir de pequenas alterações, por esse motivo existe uma terceira etapa, responsável por tentar melhorar a probabilidade de sucesso de um conjunto de prensões.

O sistema de Danielczuk et al. (2021) utiliza prensões 6-DoF para agarrar objetos colocados sobre uma mesa. Uma política de prensão é treinada em um ambiente de aprendizagem por reforço com base em um algoritmo

MPPI (*Model Predictive Path Integral*) (Williams et al., 2017) desenvolvido para reorganização de objetos em mesas. Apresentam também o modelo denominado *Scene-CollisionNet*, responsável por avaliar a probabilidade da geração de colisões durante a execução de prensões.

O sistema proposto por Wang et al. (2022a) utiliza um modelo de aprendizagem por reforço baseado na utilização de uma política hierárquica de prensão de dois níveis. A política de alto-nível gera amostras de trajetórias que resultariam em uma prensão e as incorpora em um espaço latente. Uma rede do tipo crítico treinada por *Q-Learning* decodifica o espaço latente e seleciona a trajetória com maior pontuação. A política de baixo-nível deve executar a prensão 6-DoF com base na trajetória escolhida, de modo a evitar obstáculos.

Por outro lado, o trabalho de Breyer et al. (2021) utiliza um modelo que segue uma metodologia *one-shot* com fortes influências no trabalho de Morrison et al. (2018). Diferindo de outros trabalhos, os autores optaram por converter a nuvem de pontos em voxels, dessa forma evitando problemas comuns na utilização de nuvens de pontos, como áreas com densidades variáveis de informação e o desordenamento dos pontos. Para cada voxel a rede infere, de forma semelhante ao trabalho de Morrison et al. (2018), uma métrica de qualidade (probabilidade de sucesso), abertura e rotação da garra, nesse caso de forma tridimensional e representada por quatérnios. O método é também capaz de levar em conta possíveis colisões no cálculo de probabilidade de sucesso. Utilizando um computador equipado com uma GPU, relatam terem sido capazes de planejar prensões 6-DoF em apenas 10ms.

Apesar da existência de trabalhos como os de Breyer et al. (2021), a grande maioria dos sistemas de geração de prensões 6-DoF apresentam grandes quantidades de parâmetros treináveis e dependência de múltiplas etapas para a geração e refinamento de prensões. Por esse motivo, costumam depender de altos tempos de treinamento e inferência, dificultando a aplicação em aplicações que dependem de respostas em tempo real. A utilização de estratégias que simplifiquem a representação das prensões, como feito por Zhu et al. (2022) para o caso de prensões planares, ou a utilização de estratégias do tipo *one-shot*, como feito por Breyer et al. (2021) parece ser uma caminho que ainda podem ser explorados.

4.2 Prensão em ambientes dinâmicos

Apesar dos grandes avanços evidenciados no campo de prensão robótica, um número pequeno de trabalhos lida com objetos desconhecidos em ambientes dinâmicos, assim como apontam Marturi et al. (2019); Morrison et al. (2018); Breyer et al. (2021). Mesmo abordagens relativamente recentes que empregam métodos baseados em aprendizagem profunda se limitam ao desenvolvimento de modelos em malha-aberta, incapazes de lidar com mudanças no ambiente.

Levine et al. (2016) foi um dos primeiros trabalhos a adotar um sistema em malha-fechada com retro-alimentação contínua por meio de câmeras RGB-D. Apesar do exposto, mesmo o referido trabalho não realiza qualquer estudo que tenha como objetivo avaliar a capacidade de lidar

com ambientes dinâmicos. Um possível motivo poderia ser o processamento relativamente lento, fruto das grandes proporções da rede utilizada, a qual permite apenas a repetição de análises e pré-processamentos em frequências que variam entre 2 a 5Hz. Tal limitação é resolvida na abordagem de Morrison et al. (2018), na qual o sistema permite o processamento a frequências próximas a 50Hz.

Apesar de abordagens como as de Kalashnikov et al. (2018); Viereck et al. (2017); Morrison et al. (2018, 2019) terem sido testadas em ambientes dinâmicos, testes neste tipo de cenário foram limitados e apresentaram resultados inferiores a 90% de sucesso, algo que pode inviabilizar a aplicação em ambientes reais. Marturi et al. (2019) apresentaram resultados levemente superiores, porém essa abordagem depende de uma etapa anterior de digitalização do objeto a partir de 4 diferentes pontos de vista e posterior geração de um modelo em 3D do objeto, algo que pode não ser tão facilmente alcançado em ambientes reais, seja devido à oclusão gerada por outros objetos ao redor ou mesmo pelo tempo necessário para a digitalização do objeto e respectiva geração dos modelos 3D.

4.3 Preensão Seletiva e Direcionadas a Tarefas

A literatura também demonstra um crescente interesse dos pesquisadores pelas áreas de preensões seletivas (Jang et al., 2017; Danielczuk et al., 2019; Viturino et al., 2020; Danielczuk et al., 2020) e preensões direcionadas a tarefas (Antanas et al., 2019; Liu et al., 2020; Murali et al., 2020a; Wang et al., 2022a). No contexto de preensões seletivas, os sistemas apresentam a habilidade de realizar preensões em objetos específicos. Já os sistemas de preensões direcionadas a tarefas, algumas vezes conhecidas como preensões semânticas, podem ainda realizar adequações na preensão com base na tarefa a ser desenvolvida.

Jang et al. (2017) propõem uma arquitetura que segue duas linhas de fluxo distintas para realizar preensões seletivas. A primeira linha é responsável pela classificação de objetos, enquanto a segunda trata as preensões sem se preocupar com a classe a qual o objeto pertence. O modelo recebe como entrada duas imagens, uma registrada antes do início da operação de preensão, e outra correspondente a registros mais atuais obtidos durante o processo. Os autores apontam que a utilização de duas imagens registradas em momentos diferentes auxilia no caso de oclusões geradas pelo próprio robô.

No trabalho de Viturino et al. (2020) é apresentado um sistema que faz a integração de um modelo de preensão e um sistema de detecção de objetos. Para a geração de preensões foi escolhida a arquitetura de Morrison et al. (2018), enquanto que para a tarefa de classificação de objetos adotou-se o modelo de detecção de objetos de Liu et al. (2016). O sistema resultante, treinado por meio de aprendizagem supervisionada, é capaz de reconhecer e gerar preensões em objetos pertencentes a classes específicas, ignorando objetos de todas as outras classes não desejadas.

Outro exemplo é o sistema de Danielczuk et al. (2020), o qual recebe a imagem RGB-D da área de trabalho em conjunto com a imagem de um objeto alvo que deve ser encontrado em uma pilha de objetos. Para encontrar o objeto, uma política é treinada por meio de aprendizagem

por reforço, para comparar o objeto alvo com um mapa que representa a distribuição de ocupações da pilha de objetos.

O método proposto por Liu et al. (2020) pode ser dividido em: percepção e raciocínio. O módulo de percepção detecta os atributos do objeto (habilidades de cortar, conter, etc) e o material que os constitui, de modo a formar uma representação semântica do contexto. Esse módulo integra o modelo de detecção de objetos *AffordanceNet* Do et al. (2018) com a metodologia e arquitetura de Erickson et al. (2019) para a identificação de materiais. O módulo de raciocínio relaciona, por meio de uma rede neural, as características extraídas no módulo anterior com a preensão semântica que o sistema deve realizar.

Murali et al. (2020a) utilizam uma arquitetura GCN Kipf e Welling (2016) para a realização de preensões específicas para tarefas. Para geração da relação semântica entre tarefa e objeto, utilizam os conceitos de incorporação de palavras (*word embedding*) e gráficos de compreensão (*knowledge graphs*). A partir do sistema de compreensão semântica proposto pelos referidos autores, se faz possível a generalização para novos objetos, classes e tarefas.

O sistema de Iqbal et al. (2020) adota aprendizagem profunda por reforço para realizar preensões em objetos a partir de posições específicas. Em seu trabalho realizaram o treinamento do modelo por meio de simulação. A validação foi realizada tanto por simulação como em um ambiente real. Os autores apontam que, conforme previsto em trabalhos anteriores, a transferência do aprendizado por reforço, obtido por meio do ambiente de simulação, para um ambiente real não é facilmente alcançado, não sendo possível reproduzir de maneira robusta os resultados alcançados no primeiro ambiente.

Por permitirem não só a preensão/manipulação de ferramentas como a execução de tarefas que dependam dessas, a evolução da área de preensões semânticas pode aumentar ainda mais a gama de aplicações futuras nas quais robôs manipuladores poderão estar inseridos.

5. CONCLUSÃO

O presente trabalho apresentou uma breve revisão da literatura a respeito das técnicas baseadas em aprendizagem profunda para a criação de sistemas de geração de preensões robóticas. Houve uma breve comparação entre as técnicas de treinamento supervisionado e por reforço para a geração de preensões, e entre abordagens dependentes de múltiplas etapas e estratégias do tipo *one-shot*. Ao final foram apresentadas áreas nas quais se observa um interesse crescente por parte dos pesquisadores, além de uma discussão sobre os passos futuros que poderão ser seguidos em cada uma delas.

Pode-se observar que com a ampliação das habilidades dos sistemas de geração de preensões, também ocorre o aumento da complexidade do treinamento e a exigência cada vez maior de bases de dados rotuladas e específicas. Dessa forma é possível notar que a utilização de modelos de aprendizagem por reforço parece demonstrar maior praticidade na adequação a esses desafios. Devido à sua capacidade de aprendizagem por meio de tentativa e erro, dispensam o uso bases de dados previamente rotulados e a necessidade excessiva de intervenções humanas. Algo que

pode também ser notado é que apesar do grande número de trabalhos que empregam prensões planares, não há como negar as vantagens da utilização de sistemas capazes de gerar prensões do tipo 6-DoF, demonstrando maiores possibilidades na adequação a uma gama mais ampla de tarefas.

REFERÊNCIAS

- Antanas, L., Moreno, P., Neumann, M., de Figueiredo, R.P., Kersting, K., Santos-Victor, J., e De Raedt, L. (2019). Semantic and geometric reasoning for robotic grasping: a probabilistic logic approach. *Autonomous Robots*, 43(6), 1393–1418.
- Atzmon, M., Maron, H., e Lipman, Y. (2018). Point convolutional neural networks by extension operators. *arXiv preprint arXiv:1803.10091*.
- Bohg, J., Morales, A., Asfour, T., e Kragic, D. (2013). Data-driven grasp synthesis—a survey. *IEEE Transactions on Robotics*, 30(2), 289–309.
- Breyer, M., Chung, J.J., Ott, L., Siegwart, R., e Nieto, J. (2021). Volumetric grasping network: Real-time 6 dof grasp detection in clutter. *arXiv preprint arXiv:2101.01132*.
- Caldera, S., Rassau, A., e Chai, D. (2018). Review of deep learning methods in robotic grasp detection. *Multimodal Technologies and Interaction*, 2(3), 57.
- Danielczuk, M., Angelova, A., Vanhoucke, V., e Goldberg, K. (2020). X-ray: Mechanical search for an occluded object by minimizing support of learned occupancy distributions. In *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 9577–9584. IEEE.
- Danielczuk, M., Kurenkov, A., Balakrishna, A., Matl, M., Wang, D., Martín-Martín, R., Garg, A., Savarese, S., e Goldberg, K. (2019). Mechanical search: Multi-step retrieval of a target object occluded by clutter. In *2019 International Conference on Robotics and Automation (ICRA)*, 1614–1621. IEEE.
- Danielczuk, M., Mousavian, A., Eppner, C., e Fox, D. (2021). Object rearrangement using learned implicit collision functions. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 6010–6017. IEEE.
- Depierre, A., Dellandréa, E., e Chen, L. (2018). Jacquard: A large scale dataset for robotic grasp detection. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 3511–3516. IEEE.
- Do, T.T., Nguyen, A., e Reid, I. (2018). Affordancenet: An end-to-end deep learning approach for object affordance detection. In *2018 IEEE international conference on robotics and automation (ICRA)*, 1–5. IEEE.
- Erickson, Z., Luskey, N., Chernova, S., e Kemp, C.C. (2019). Classification of household materials via spectroscopy. *IEEE Robotics and Automation Letters*, 4(2), 700–707.
- Goodfellow, I., Bengio, Y., Courville, A., e Bengio, Y. (2016). *Deep learning*, volume 1. MIT press Cambridge.
- Guo, W., Dong, G., Chen, C., e Li, M. (2019). Learning pushing skills using object detection and deep reinforcement learning. In *2019 IEEE International Conference on Mechatronics and Automation (ICMA)*, 469–474. IEEE.
- Guo, Y., Wang, H., Hu, Q., Liu, H., Liu, L., e Bennamoun, M. (2020). Deep learning for 3d point clouds: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 43(12), 4338–4364.
- Hua, B.S., Tran, M.K., e Yeung, S.K. (2018). Pointwise convolutional neural networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 984–993.
- Huang, H., Dominguez-Kuhne, M., Satish, V., Danielczuk, M., Sanders, K., Ichnowski, J., Lee, A., Angelova, A., Vanhoucke, V., e Goldberg, K. (2020). Mechanical search on shelves using lateral access x-ray. In *2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2045–2052. IEEE.
- Ichnowski, J., Danielczuk, M., Xu, J., Satish, V., e Goldberg, K. (2020). Gomp: Grasp-optimized motion planning for bin picking. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 5270–5277. IEEE.
- Iqbal, S., Tremblay, J., Campbell, A., Leung, K., To, T., Cheng, J., Leitch, E., McKay, D., e Birchfield, S. (2020). Toward sim-to-real directional semantic grasping. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 7247–7253. IEEE.
- Jang, E., Vijayanarasimhan, S., Pastor, P., Ibarz, J., e Levine, S. (2017). End-to-end learning of semantic grasping. *arXiv preprint arXiv:1707.01932*.
- Kalashnikov, D., Irpan, A., Pastor, P., Ibarz, J., Herzog, A., Jang, E., Quillen, D., Holly, E., Kalakrishnan, M., Vanhoucke, V., et al. (2018). Qt-opt: Scalable deep reinforcement learning for vision-based robotic manipulation. *arXiv preprint arXiv:1806.10293*.
- Kipf, T.N. e Welling, M. (2016). Semi-supervised classification with graph convolutional networks. *arXiv preprint arXiv:1609.02907*.
- Kleeberger, K., Bormann, R., Kraus, W., e Huber, M.F. (2020). A survey on learning-based robotic grasping. *Current Robotics Reports*, 1(4), 239–249.
- Kumra, S. e Kanan, C. (2017). Robotic grasp detection using deep convolutional neural networks. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 769–776. IEEE.
- Lenz, I., Lee, H., e Saxena, A. (2015). Deep learning for detecting robotic grasps. *The International Journal of Robotics Research*, 34(4-5), 705–724.
- Levine, S., Pastor, P., Krizhevsky, A., e Quillen, D. (2016). Learning hand-eye coordination for robotic grasping with large-scale data collection. In *International Symposium on Experimental Robotics*, 173–184. Springer.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.Y., e Berg, A.C. (2016). Ssd: Single shot multibox detector. In *European conference on computer vision*, 21–37. Springer.
- Liu, W., Daruna, A., e Chernova, S. (2020). Cage: Context-aware grasping engine. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 2550–2556. IEEE.
- Mahler, J., Liang, J., Niyaz, S., Laskey, M., Doan, R., Liu, X., Ojea, J.A., e Goldberg, K. (2017). Dex-net 2.0: Deep learning to plan robust grasps with synthetic point clouds and analytic grasp metrics. *arXiv preprint arXiv:1703.09312*.
- Mahler, J., Matl, M., Liu, X., Li, A., Gealy, D., e Goldberg, K. (2018). Dex-net 3.0: Computing robust vacuum suction grasp targets in point clouds using a new analytic

- model and deep learning. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, 1–8. IEEE.
- Mahler, J., Matl, M., Satish, V., Danielczuk, M., DeRose, B., McKinley, S., e Goldberg, K. (2019). Learning ambidextrous robot grasping policies. *Science Robotics*, 4(26).
- Mahler, J., Pokorny, F.T., Hou, B., Roderick, M., Laskey, M., Aubry, M., Kohlhoff, K., Kröger, T., Kuffner, J., e Goldberg, K. (2016). Dex-net 1.0: A cloud-based network of 3d objects for robust grasp planning using a multi-armed bandit model with correlated rewards. In *2016 IEEE international conference on robotics and automation (ICRA)*, 1957–1964. IEEE.
- Marturi, N., Kopicki, M., Rastegarpanah, A., Rajasekaran, V., Adjigble, M., Stolkin, R., Leonardis, A., e Bekiroglu, Y. (2019). Dynamic grasp and trajectory planning for moving objects. *Autonomous Robots*, 43(5), 1241–1256.
- Mohammed, M.Q., Chung, K.L., e Chyi, C.S. (2020). Review of deep reinforcement learning-based object grasping: Techniques, open challenges, and recommendations. *IEEE Access*, 8, 178450–178481.
- Morrison, D., Corke, P., e Leitner, J. (2018). Closing the loop for robotic grasping: A real-time, generative grasp synthesis approach. *arXiv preprint arXiv:1804.05172*.
- Morrison, D., Corke, P., e Leitner, J. (2019). Learning robust, real-time, reactive robotic grasping. *The International Journal of Robotics Research*, 0278364919859066.
- Morrison, D., Corke, P., e Leitner, J. (2020). Egrad! an evolved grasping analysis dataset for diversity and reproducibility in robotic manipulation. *IEEE Robotics and Automation Letters*.
- Mousavian, A., Eppner, C., e Fox, D. (2019). 6-dof graspnet: Variational grasp generation for object manipulation. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2901–2910.
- Murali, A., Liu, W., Marino, K., Chernova, S., e Gupta, A. (2020a). Same object, different grasps: Data and semantic knowledge for task-oriented grasping. *arXiv preprint arXiv:2011.06431*.
- Murali, A., Mousavian, A., Eppner, C., Paxton, C., e Fox, D. (2020b). 6-dof grasping for target-driven object manipulation in clutter. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 6232–6238. IEEE.
- Pinto, L. e Gupta, A. (2016). Supersizing self-supervision: Learning to grasp from 50k tries and 700 robot hours. In *2016 IEEE international conference on robotics and automation (ICRA)*, 3406–3413. IEEE.
- Pinto, L. e Gupta, A. (2017). Learning to push by grasping: Using multiple tasks for effective learning. In *2017 IEEE international conference on robotics and automation (ICRA)*, 2161–2168. IEEE.
- Qi, C.R., Su, H., Mo, K., e Guibas, L.J. (2017a). Pointnet: Deep learning on point sets for 3d classification and segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 652–660.
- Qi, C.R., Yi, L., Su, H., e Guibas, L.J. (2017b). Pointnet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in neural information processing systems*, 30.
- Redmon, J. e Angelova, A. (2015). Real-time grasp detection using convolutional neural networks. In *2015 IEEE International Conference on Robotics and Automation (ICRA)*, 1316–1322. IEEE.
- Roa, M.A. e Suárez, R. (2015). Grasp quality measures: review and performance. *Autonomous robots*, 38(1), 65–88.
- Shimoga, K.B. (1996). Robot grasp synthesis algorithms: A survey. *The International Journal of Robotics Research*, 15(3), 230–266.
- Song, S., Zeng, A., Lee, J., e Funkhouser, T. (2020). Grasping in the wild: Learning 6dof closed-loop grasping from low-cost demonstrations. *IEEE Robotics and Automation Letters*, 5(3), 4978–4985.
- Sun, M. e Gao, Y. (2021). Gater: Learning grasp-action-target embeddings and relations for task-specific grasping. *IEEE Robotics and Automation Letters*, 7(1), 618–625.
- Sun, Z., Yuan, K., Hu, W., Yang, C., e Li, Z. (2020). Learning pregrasp manipulation of objects from ungraspable poses. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 9917–9923. IEEE.
- Sundermeyer, M., Mousavian, A., Triebel, R., e Fox, D. (2021). Contact-graspnet: Efficient 6-dof grasp generation in cluttered scenes. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, 13438–13444. IEEE.
- Thomas, H., Qi, C.R., Deschard, J.E., Marcotegui, B., Goulette, F., e Guibas, L.J. (2019). Kpconv: Flexible and deformable convolution for point clouds. In *Proceedings of the IEEE/CVF international conference on computer vision*, 6411–6420.
- Viereck, U., Pas, A.t., Saenko, K., e Platt, R. (2017). Learning a visuomotor controller for real world robotic grasping using simulated depth images. *arXiv preprint arXiv:1706.04652*.
- Viturino, C., Santana Filho, K., Oliveira, D., Lemos, C., e Conceicao, A. (2020). Redes neurais convolucionais para identificação e prensão robótica de objetos. *XXIII Congresso Brasileiro de Automática*.
- Wang, L., Meng, X., Xiang, Y., e Fox, D. (2022a). Hierarchical policies for cluttered-scene grasping with latent plans. *IEEE Robotics and Automation Letters*.
- Wang, L., Xiang, Y., Yang, W., Mousavian, A., e Fox, D. (2022b). Goal-auxiliary actor-critic for 6d robotic grasping with point clouds. In *Conference on Robot Learning*, 70–80. PMLR.
- Wang, Z., Li, Z., Wang, B., e Liu, H. (2016). Robot grasp detection using multimodal deep convolutional neural networks. *Advances in Mechanical Engineering*, 8(9), 1687814016668077.
- Williams, G., Aldrich, A., e Theodorou, E.A. (2017). Model predictive path integral control: From theory to parallel computation. *Journal of Guidance, Control, and Dynamics*, 40(2), 344–357.
- Zeng, A., Song, S., Welker, S., Lee, J., Rodriguez, A., e Funkhouser, T. (2018). Learning synergies between pushing and grasping with self-supervised deep reinforcement learning. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 4238–4245. IEEE.
- Zhu, X., Wang, D., Biza, O., Su, G., Walters, R., e Platt, R. (2022). Sample efficient grasp learning using equivariant models. *arXiv preprint arXiv:2202.09468*.