

谷口彰先生ご講演QA

Q. 提案アルゴリズムの計算にかかる時間。話しかけられたらロボットはすぐに動けるのでしょうか？
話しかけられたら数秒程度の遅延はあるが割とすぐに動く。並列化などによる高速化も可能
具体的な数値は論文に記載している。

Q. 実験の場所
ラボの実環境か、シミュレーション上の仮想環境(Sigverseなど)を利用している。

Q. 実験していて、実環境で行わないといけないと思った部分はなかったでしょうか？
実環境の方が難しいと思う。仮想環境上ではノイズが無い理想的なデータが出てくるが、実環境ではさまざまなノイズや不確実性が伴う。

Q. 高精度な現在の音声認識でも対応できないといけない不確実性は何か
周りの環境音の影響や、新語や未知語など環境独自の言葉への対応が考えられる。
語彙獲得のモデルとして、認知発達の誤りながらも獲得していくのがコンセプトとして大事。

Q. リアルタイムで次々にタスクを与えられる実世界でのロボットでは終端状態のようなものがなく、
Control as Inferenceの終端状態からの逆計算ができなくなる気がするのですが、どのように扱うのでしょうか？
計算上は、計画区間の最大時刻は決めている。実際は最大時刻まで行動するわけではなく、それよりも前の時刻までで達成される最適な行動が推論されることになる。
実世界上では終端状態は決められないので、次々にタスクを与えられた場合は、その都度、新しく推論をし直すことになる。

Q. 場所「概念」の獲得とのことですが、例えばモデルが学習データから獲得した「キッチン」という場所概念に基づいて、別の場所の、我々が考えるところのキッチンを同定できる(あるいはそれを目指している)ということでしょうか。
目指している。知識の転用も目指していて、新しい環境において見た画像とこれまで獲得した知識から、ここは「キッチン」だな、というような推論をできるようにしている。

Q. 言語や概念の獲得というと抽象性を捉える活動が入っている方が望ましいと思いますがどのように考えているか
抽象性は重要だと思う。これまでの取り組みでは、モデルを階層化するなどしてより抽象的な知識を獲得できるようにしている。

Q. ロボットが通った場所にラベル付けしている手法に見えるのですが、それは概念を獲得していることになるのでしょうか？
単に場所の名前をラベル付けはしているわけではない。人がいろんな言葉をしゃべったりして得られるノイズな情報からある記号がどの場所に対応しているか推定している。

Q. 概念は超大雑把に分けて「モノ(実体のある物)」と「コト(事象)」があり、今回の実験結果は「モノ」が主でしたが、コトの概念(「歩く」とはどういうことかなど)も今回の枠組みで学習できそうでしょうか？

か？

コトの概念に対応するには、今回の枠組み以上のことを考える必要がある。

(持橋) 時系列的によく出てくる内部の状態列に名前を付けているのかと思いますので、そこが抽象化できればよさそうですね。

Q. 子供を育てていて思うのですが、場所の名前については、自然に獲得するのは「風呂」など本当に数語の言葉で、後は「ここ」とか「そこ」と言った言葉が理解できるようになってから教え込んだものだと思個人的には思うのですが、自然獲得される語彙がどの程度あるかという研究はあるのでしょうか？

幼児の語彙獲得や言語獲得は認知発達や心理学の分野で研究されています。入門的な書籍として「言葉の発達の謎を解く」、「赤ちゃんはことばをどう学ぶのか」などがあります。

Q. control as inferenceの報酬に当たる情報は何か

ある行動を行うのに報酬を元々考えることなどはしない。

報酬設計を行うのではなく、ある目的における最適な行動計画を事後分布として推論するのがControl as Inferenceである。

ゴールのprobabilityが強化学習で言う報酬に対応するようになっている。

Q. SpCoNaviでControl as Inferenceを取り入れる動機について聞き逃してしまったかもしれないので伺いたいです

確率的生成モデルにおいて、確率推論として行動の推定を行うためです。Control as Inferenceは強化学習や制御を確率推論の最適化問題として落とし込むことができるため、関連した様々な手法の導入や比較が容易になると考えています。

Q. 20-21ページ目で、軌道を予測する、というのは具体的にどのように動作予測(推定?)するのでしょうか？次に進む方向と進む距離を(ある動作周波数で？あるいは動作終了ごとに？)予測する、というような感じなのでしょうか。あるいはmap上の大域的な目的位置そのものを最初から予測しているのでしょうか？

1timestepに対して地図の1セルを移動するという仮定を置いています。設定した計画区間(Time horizon)まで先の時刻までの行動を推定しています。

Q. SpCoAEはいわゆる強化学習の内発的報酬に近いものなのでしょうか？(IG最大化というのは観測していない情報が多くなるような行動を取るということだとでしょうか？)

はい、内発的報酬に対応します。

Q. 仮想環境での実験や研究活動は実世界を対象としたものに比べて少ないように思えるのですが、あまり人気がないのでしょうか？(仮想環境ならSLAMは必要なくなって実験環境も自由自在ですし、ハードウェアの構築や実験のコストも抑えられて比較的簡単なのにと考えていまして)仮想環境での研究のデメリットがあれば教えていただきたいです

仮想環境で動くモデルや実験を前提としてしまうと、いざ実世界に持っていこうとしたときに様々な制限が出てくることが問題だと思います。論文の執筆やモデルの検証と言う意味では仮想環境は便利ですが、結局それが実世界で動かないと意味がないですからね。

Q. 簡単な質問ですが、Particleの数はいくつくらいにしているのでしょうか？

30～100程

Q. 17 page目で、正しく理解できているかわかりませんが、音声からテキストやシンボリックな情報を全く経由せずに、移動先の目的位置を予測するのでしょうか。

間の潜在変数にはテキストに対応する変数があるのでテキスト情報を経由はしますが、理論的には周辺化しているため数式上は音声から目的までの経路を推定しています。

Q. Particle Filterを使っている場合は、遷移カーネルは任意に設計できるので、たとえば通常のIG最大化を90%、ランダム探索を10%などと組み合わせてみるのはどうでしょうか？

ありがとうございます。参考にさせていただきます。

Q. 最近はニューラルな手法が流行ですがニューラル手法は変数の解釈が難しいです。グラフィカルモデルの一部のコンポーネントをニューラル化して、ニューラル手法を解釈する手法の一つとして確率モデルを使うという方向性の研究はあるのでしょうか？

深層生成モデルや確率的なニューラルネットの研究があります。

Q. 常識的知識についてで、ある程度のまとまった既存概念の使いまわしなどが必要になってくると思いますが、こちらはどのように組み合わせていけば良いかなどの考えはありますか？

アプローチはいろいろ考えられるとは思いますが、素朴には様々な環境での概念を共有し汎化した概念を階層モデルの事前分布として組み込むことが考えられるかと思います。

Q. 場所概念と地図を同時推定することで地図の精度が下がることはありませんか？直感的には地図が固まってから場所が形成されるのかなと考えるのですが同時推定にした理由はありますか？

地図の精度が下がる場合も考えられますが、一方で、場所概念の影響を自己位置推定や地図生成にフィードバックすることで精度を向上させることも可能です。(簡単な予備実験では実証済みです)

また、地図の精度が下がったとしても場所概念があることによって、自己位置推定を補正することができるので、どこまでカッチリとした地図が必要か、という議論もあります。

地図を固めてから場所概念を形成させるとロボットを環境上で動かすことが2度手間になるので、同時に獲得させることで効率化しています。

Q. 大規模言語モデルとローカルに獲得した知識をつなぐ上での難しさですが、単語の切れ目が合っていないものを合わせるところにあるのでしょうか？

未知語の語彙獲得のようなボトムアップなアプローチと繋ぐ場合、単語の切れ目が異なることや単語に音素認識誤りがあることも難しさの要素になるかと思います。

Q. イントロで脳(海馬)との関係に触れていらっしゃいましたが、現状ではどのくらいの対応関係を考えていますか？ 実際に海馬で観測されている活動パターンがモデルに現れてくる、というようなことはありますか？

海馬のモデルについては今回お話しませんでした。海馬の空間認知能力とロボティクスにおけるSLAMとの対応関係についてはNeural Networks誌に掲載された論文で調査しています。

<https://www.sciencedirect.com/science/article/pii/S0893608022001332>

実際に海馬で観測されている活動パターンがモデルに現れてくる、ところまではまだ未検証です。

