スパイキングニューロンモデルを用いた 質問応答システムにおけるホログラフィック圧縮表現の評価 Evaluation of Holographic Reduced Representations in Question-Answering System using Spiking Neuron Model 岩尾 桂志^{*1} ライチェフ・ビセル^{*1} 玉木 徹^{*1} 金田 和史^{*1} Keiji Iwao Bisser Raytchev Toru Tamaki Kazufumi Kaneda

> *1広島大学大学院 工学研究科 情報工学専攻 Graduate School of Engineering, Hiroshima University

Symbolic reasoning is an important ability of the brain. Symbolic structures can be represented as distributed representations with binding operations. We aim to extend a conventional model for word or phrase level reasoning to sentence level reasoning and to find the optimal distributed representation for processing structural representations such as languages in a biological brain model under noise. We construct a spiking neuron model which can answer answer questions about a group of sentences. We employed Holographic Reduced Representations (HRRs) to prevent the increasing of vector dimensionality for binding operations. Experimental results show that our model can select an appropriate sentence for question-answering even in similar sentences. Experiments suggest that a noise-robust structural representations for languages can be realized by changing the role vector depending on the depth of the structure and by embedding a verb into a role vector and removing the predicate part.

1. 背景・目的

認知科学におけるアプローチの一つに、シンボル的アプロー チがある.これは、人間が視覚や聴覚などで得られた実世界の 連続的情報を言語というシンボルとして表現し、論理的思考 を行なっていると仮定したアプローチである.シンボルの羅 列を言語的に理解するために、個々の単語のシンボルをフィ ラー、その単語の役割をロールとし、フィラーとロールのバイ ンディングを用いて、全体の構造表現を実現することが多い [Eliasmith 13]. しかし, 実際の脳での論理的思考は, 不完全な 入力情報や変動する状況下においても巧みに動作する. そのた め,シンボルを分散表現に符号化し,ノイズ条件下においてシ ンボル的処理が行われなければならない. Gayler らは, シンボ ル構造を分散表現に符号化する Vector Symbolic Architecture (VSA)を提案した [Gayler 03]. その中でも, Plate らのホログ ラフィック圧縮表現 (Holographic Reduced Representations: HRRs) [Plate 94] では、巡回畳み込みによるバインディング 操作を用いることで,バインディングによるベクトル次元の増 加を防ぎつつ、言語表現におけるシンボル的処理が可能であ ることが示された. また, 脳は皮質, 基底核, 視床において, 入力の刺激情報と,脳の状態に応じて適切な処理を選択する行 動選択 (Action Selection) を行なっている. Eliasmith らは, 行動選択をスパイキングニューロンモデルで実装し,脳の状態 に応じた適切なシンボル的推論を HRRs により実現できるこ とを示した [Eliasmith 10]. しかし、このモデルでは、実際の 言語表現に見られるような,深い構造を持つ複雑な言語表現, 及び構造的に類似した複数の知識表現に対しての有効性は示さ れていない.

そこで本論文では、言語構造から成る複数の類似した知識表 現を記憶し、その中のある一つの知識に対する質問に対してシ ンボル的推論を行い、適切な応答を返すスパイキングニューロ ンモデルを提案することを目的とする.また、モデルを用いた 実験結果から、質問応答システムにおける知識構造の最適な表 現について考察する.まず、次節でスパイキングニューロンモ

連絡先: 岩尾桂志, 広島大学大学院 工学研究科 情報工学専攻, keiji-iwao@hiroshima-u.ac.jp デルを実装するための, Eliasmith らが提案した NEF (Neural Engineering Framework) [Eliasmith 03] について説明し, 3 節で, HRRs 及び言語構造的知識の表現方法について説明す る. その後, 4 節で, 従来モデルを拡張するための提案手法に ついて説明する. 最後に, モデルの精度を検証するための実験 と結果から, 言語や知識表現などの構造表現における最適な表 現について考察する.

2. NEF

本論文では, Eliasmith らの NEF (Neural Engineering Framework)というフレームワークを用いてスパイキングニュー ロンモデルを実装する. NEF では,ニューロン集団は,情報 となるベクトル値を入力として受け取り,スパイクを介したエ ンコーディング・デコーディング過程により情報を保持する. エンコーディングは,式(1)で表される.

$$a_i(\boldsymbol{x}) = \sum_m \delta(t - t_{im}) \tag{1}$$

ここで, *a* はニューロンの活動, *x* は入力ベクトル, *m* はスパ イクのインデックス, *i* はニューロンのインデックスである. また, デコーディングは, 式 (2) で表される.

$$\hat{\boldsymbol{x}} = \sum_{i,m}^{N,M} h_i (t - t_{im}) \boldsymbol{d}_i \tag{2}$$

ここで, \hat{x} は x のデコーディング結果, N はニューロン数, M はスパイク数, i はニューロンのインデックス, m はスパ イクのインデックス, h(t) はシナプス後電流 (Post Synaptic Current : PSC), d_i はデコーディングベクトルである. また, 本論文では, Leaky-Integrate and Fire (LIF) ニューロンを 用いた. LIF ニューロンの発火頻度は,入力の大きさによって 変化し,神経調和曲線に基づいて決定するが,詳細な説明は省 略する [Bekolay 14].

3. シンボル構造表現の分散表現

3.1 ホログラフィック圧縮表現

HRRs は、バインディング操作に巡回畳み込みを用いる VSA の一つである. 一般に、n 次元の 2 つのベクトル $c \ge x$ の巡回畳み込み結果 t の j 番目の要素は、次式で表される.

$$t_j = \sum_{k=0}^{n-1} c_k x_{j-k}$$
(3)

また, $t \in c$ でアンバインディングした結果 $y \circ j$ 番目の要素は次式で表される.

$$y_j = \sum_{k=0}^{n-1} c_k t_{k+j} \tag{4}$$

ベクトル c 及び x c,大きさ 1,要素が平均 0,分散 $\frac{1}{n}$ の正規 分布 $N(0, \frac{1}{n})$ に従うように取ることで, $y = x + noise \approx x$ となり、シンボル的推論を固定長ベクトルで実現できる.

3.2 構造表現

本論文で用いる知識表現は,主語,述語,目的語からなる文 表現で考慮する.例として,"The dog chases the boy."とい う文は,次のように表すことができる.

$$S1 = Agent * Dog + Verb * Chase + Object * Boy$$
 (5)

ここで,*はバインディングである. 各シンボルにベクトル を割り当て, Dog, Chase, Boy などのフィラーベクトルと Agent, Verb, Object などのロールベクトルを,式(3)の巡 回畳み込みによるバインディングを用いることで,文をベクト ルで表現する.また,式(4)により,文表現からシンボルを抽 出する.

$$S1 \otimes Object \approx Boy$$
 (6)

ここで、 \otimes はアンバインディング記号である.シンボル構造 の特徴は、構造表現を効率的に表現できることである."The dog chases the boy who has a ball."という文は、次のように 表される.

S2 = Agent * Dog + Verb * Chase + Object *

(Agent * Boy + Verb * Play + Object * Ball) (7)

また,アンバインディングにより,文そのものを推論すること も可能である.

 $S2 \otimes Object \approx Agent * Boy + Verb * Play + Object * Ball$ (8)

4. モデル

図 1 にモデルの概要を示す.まず,入力である文章を text_input より, ラベル用ベクトル STATEMENT-n を加え て入力する.text_input は順に入力される文を表現し,フィー ドバック要素を持つニューロン集団 m1 から m20 のいずれか へ送る.この際,基底核 bg1 及び視床 thal1 の行動選択によ り,各入力文は異なるニューロン集団に送られ,記憶される. ここで本論文では,20 文からなる文章を用いるため,文章を 記憶するためのニューロン集団 m を 20 個定義した.

全ての文が入力された後,質問を入力する.ここで,質問とは, アンバインディングに用いられるベクトルを指し,text_input から入力され question へ送られる.また,質問入力と同時間, 適切な文を選択するためのベクトルを cue_input より入力す る.この際,基底核 bg2 及び視床 thal2 により,式(9) で表 される内積が最大となる n を決定し,対応する memory_n を question でアンバインディングした結果を out へ送る.ここ で Sentence_n は, n 番目の文ベクトルを表す.

$$n^* = \operatorname*{argmax}_{1 \le n \le 20} dot(cue_input, Sentence[n])$$
(9)

表1に,式(5)を入力文章とした例のシミュレーションの流 れを示す.



Figure 1: 本論文で用いるスパイキングニューロンモデル

5. 実験

本論文では、文の構造の深さを1から4の4レベルとし、各レ ベルに対してそれぞれ異なる5文,計20文を用いる.まず,名詞 500単語(**N1,...N500**)、及び動詞500単語(**V1,...,V500**) に対し、 $N(0, \frac{1}{n})$ に従うランダムなベクトルをフィラーベクト ルとして割り当てる.フィラーベクトルにバインディングす るロールベクトルや後述する ID(Identity) ベクトルもまた、 同条件で定義する.

実験では,以下で説明する条件 A~ 条件 H の表現方法を用 いて 20 文を表現する.ここで条件 A~C が従来の表現方法, D~H がオリジナルの表現方法である.

- 条件A:ロールベクトルには, Agent1, Verb1, Object1 の3個のみ用いる.
- 条件 B: 文の深さごとに異なるロールベクトルを割り当て るため、ロールベクトルには、Agent1 ~ Agent4、Verb1 ~ Verb4、Object1 ~ Object4 を用いる. 1~4 は文内の 深さに対応する.
- 条件 C: 述語部のロールベクトル Verb を除去し, Agent, Object をそれぞれ Agent_{Vn}, Object_{Vn} に次の ように置き換えることで、ベクトル V が動詞の役割を持 つことを示す.

 $Agent_{Vn} = (Agent + ID_{Vn_agt})/\sqrt{2} \quad (10)$

 $Object_{Vn} = (Object + ID_{Vn_{obj}})/\sqrt{2} \quad (11)$

条件 D~H は, ロールベクトル Verb 及び動詞 Vn を, Agent_{Vn}, Object_{Vn} に埋め込む. Table 1: Agent * Dog + Verb * Chase + Object * Boy を入力文とした際のシミュレーション例

時間	text_input	cue_input	question	正答
0 < t < 0.2	Agent*Dog+Verb*Chase+Object*Boy	None	None	None
0.2 < t < 0.4	None	Verb*Chase+Object*Boy	Agent	Dog
0.4 < t < 0.6	None	Agent*Dog+Verb*Chase	Object	Boy



Figure 2: 各表現方法における例文

 条件 D:各ロールベクトルには、述語のフィラーベクト ルとの和を用いる。

$$Agent_{Vn} = (Agent + Vn)/\sqrt{2}$$
(12)

$$Object_{Vn} = (Object + Vn)/\sqrt{2}$$
(13)

条件 E:各ロールベクトルには、述語フィラーベクトルとの巡回畳み込みを用いる。

$$Agent_{Vn} = Agent * Vn \tag{14}$$

$$Object_{Vn} = Object * Vn \tag{15}$$

 条件 F:各ロールベクトルには、深さによって区別した 各ロールベクトルと述語フィラーベクトルの和を用いる。

 $Agent_{Vn} = (Agent_n + Vn)/\sqrt{2} \qquad (16)$

- $Object_{Vn} = (Object_n + Vn)/\sqrt{2} \qquad (17)$
- 条件G:各ロールベクトルには、深さによって区別した 各ロールベクトルと述語フィラーベクトルの巡回畳み込 みを用いる。

$$Agent_{Vn} = Agent_{n} * Vn \tag{18}$$

$$Object_{Vn} = Object_n * Vn \tag{19}$$

 条件 H:各ロールベクトルには、深さによって区別し重 み付けされた各ロールベクトルと述語フィラーベクトル との和を用いる。

 $Agent_{Vn} = (2 \times Agent_{n} + Vn)/\sqrt{3} \qquad (20)$

$$Object_{Vn} = (2 \times Object_n + Vn)/\sqrt{3}$$
(21)

各文および各質問の入力時間は、1 つあたり 0.2[s] とした. 表1に、"The dog chases the boy."という1 文のみが入力文 章であり、条件 A で表現した場合のシミュレーションの流れ を例として示す. 質問は、例における Dog や Boy など、入力 文の主語部及び目的語部に対するすべての質問を考慮する. 前 述の通り、実験には 20 文を用いて、合計 100 個の質問を考慮 した. 各質問の入力終了時点におけるニューロン集団 out が 表現したベクトルと、ネットワーク内の全てのフィラーベクト ルとの類似度を計算し、最大類似度のベクトルをモデルの出力 とする. 各条件に対して、24[s] のシミュレーションをそれぞ れ5 回行ない、正答率の平均値で評価した.

5.1 結果·考察

各条件における正答率を表したグラフを図3に示す. 横軸は 文の深さレベル,縦軸は正答率を表す.また,質問の難易度を 示すため,文の深さレベルだけでなく質問の深さレベルによっ て正答率を示した.図3aと図3b,図3dと図3f,図3eと図 3gの比較から,構造の深さによって異なるロールベクトルを 用いた方が正答率が高いことがわかる.これは,同じロールベ クトルを用いると文同士の類似度が大きくなるため,式(9)に



Figure 3: 各表現方法の正答率

おいて誤った行動に対応する内積が最大になるからだと考えら れる. また,図 3c と図 3d から,述語のフィラーベクトルを ロールベクトルに埋め込むことで,類似した文の類似度を抑え ることができることがわかる.図 3f では、複雑な文において、 複雑な質問より簡単な質問の方が正答率が低くなっている.こ の原因として,式(16),(17)のAgent_{Vn}とObject_{Vn} が類似するため、Agent_{Vn} によるアンバインディング結果 だけでなく、Object_{Vn} によるアンバインディング結果も 同時に出力されるためだと考えられる.しかし,図 3g から, 複雑な質問に対しては、巡回畳み込みより加算によるロールベ クトルを用いた方が正答率が高くなることがわかる. 巡回畳み 込みによるロールベクトルが複雑な質問において有効でない 理由として,一般的に巡回畳み込み結果が元のベクトルとのど ちらとも類似しないベクトルにマッピングされることが原因 として考えられる、ベクトル次元を増加させることが対策と して考えられる. さらに、図 3h では、全体的な平均正答率が 良く,分散も抑えられていることがわかる.これは,式(20), (21)のように、Agent_{Vn}とObject_{Vn}に共通する述語 フィラーベクトル Vn を相対的に弱める重み付けをすること で、Agent_{Vn} と Object_{Vn} をより区別できるからだと 考えられる.

6. おわりに

本論文では、文表現に対するシンボル的推論において、複数 の知識表現から質問に関連する文を取り出して推論するモデ ルを提案した.また、生物学的なノイズ条件下においても有効 な表現方法を実験によって評価した.複数の類似した表現に 対しては、パインディングするロールベクトルを可能な限り 区別することで、ノイズ条件下でも有効な表現が実現できる ことがわかった.本論文では、各シンボルに対して割り当てる ベクトルを、どの二つも類似度が 0.1 以下、つまり意味的に類 似しないようにランダムに定義している.今後の課題として、 Word2Vec[Mikolov 13] などの意味的な類似度を分散表現に埋 め込んだベクトルや、SNN において最適化されたランダムベ クトル [Gosmann 16] を用いた場合の実験を行う必要がある.

References

- [Bekolay 14] Bekolay, T., et al.: Nengo: A Python tool for building large-scale functional brain models, *Frontiers* in Neuroinformatics (2014)
- [Eliasmith 03] Eliasmith, C., Anderson, C. H.: Neural Engineering: Computation, Representation, and Dynamics in Neurobiological Systems *MIT press* (2003)
- [Eliasmith 10] Stewart, T. C., Choo, X., and Eliasmith, C.: Symbolic Reasoning in Spiking Neurons: A Model of the Cortex/Basal Ganglia/Thalamus Loop, In 32nd Annual Meeting of the Cognitive Science Society, Austin, TX: Cognitive Science Society (2010)
- [Eliasmith 13] Eliasmith, C.: How to Build a Brain: A Neural Architecture for Biological Cognition, Oxford University Press (2013)
- [Gayler 03] Gayler, R.: Vector Symbolic Architectures answer Jackendoff's challenges for cognitive neuroscience, *ICCS/ASCS, International Conference on Cognitive Science*, Sydney, Australia: University of New South Wales, pp. 133-138 (2003)
- [Gosmann 16] Gosmann, J. and Eliasmith, C.: Optimizing Semantic Pointer Representation for Symbol-Like Processing in Spiking Neural Network, *PLoS ONE* 11(2): e0149928. doi: 10.1371/journal.pone.0149928 (2016)
- [Mikolov 13] Mikolov, T., Chen, K., Corrado, G., and Dean, J.: Efficient estimation of word representations in vector space, *ICLR*, *International Conference on Learning Representations 2013* (2013)
- [Plate 94] Plate, T.: Holographic reduced representations, Stanford, CA:CSLI Publication (1994)