

DLPFC を想定した修正エルマンネットによる Elman (1991) と Rohde and Plaut (1999) の再検証

Re-Examining Elman (1991) and Rohde and Plaut (1999)
Using a Modified Elman Net with DLPFC Function

石崎 貴士

菅原 友佳¹

Takashi ISHIZAKI

Tomoka SUGAWARA

Elman (1991), using his Elman Net, showed that in order to complete the task of learning relative pronouns it is necessary to grade input based on the ratio of complex sentences to simple sentences. However, Rohde and Plaut (1999) argued that such a graded input is not necessary with semantic constraints. This study re-examines Elman's claim that graded input is necessary if semantic factors are eliminated and grading is not based on the ratio of complex sentences to simple sentences, but rather on the complexity of sentence structure. In Study I, the Elman Net was used, and it failed to complete the task both with and without graded input. Thus, Study II used a modified Elman Net with ACC monitoring function (Ishizaki & Nakamura, 2019, 2020), which still failed to complete the task both with and without graded input. Finally, in Study III, a modified Elman Net with DLPFC monitoring function was used, and it completed the task with graded input; however, it still failed to complete the task without graded input.

[キーワード] コネクショニズム, エルマンネット, ACC, DLPFC

¹ 山形大学地域教育文化学部 4 年次生 (2021 年 3 月当時)

1. 研究の背景

1.1 コネクショニズムとは

コネクショニズム (connectionism) とは, 人間の脳内の神経細胞がどのように働いているのか, その働きにヒントを得て考案された情報処理モデルのことである。脳内の神経細胞一つ一つが行っているのは興奮と伝達というきわめて単純な作業であるが, それを膨大な数で構成された神経細胞のネットワーク上で一斉に分散して行うことにより, 従来は規則を適用してなされると考えられていたレベルの情報処理も, 規則を適用することなくネットワーク間の結合強度と個々の神経細胞の閾値を調整することのみで実行可能となることを, 当該分野ではコンピュータを用いたシミュレーションによって実証してきた (守 1996)。

1.2 Elman (1991)

コネクショニズムでのシミュレーションのためにコンピュータ上に構築される神経細胞のネットワークは, 提示する課題によってタイプが異なる。例えば, Rumelhart & McClelland (1986) が行った, 英語の動詞の原形を入力するとそれに対応する過去形を出力する学習シミュレーションではパーセプトロン型のネットワークが用いられた。しかし, Elman (1991) のように関係詞節を含んだ複雑な英文の統語 (語順) を学習させるような場合は, パーセプトロン型のネットワークは適さない。なぜなら, パーセプトロン型のネットワークは特定の対応パターンを学習することにおいては有効であるが, 統語 (語順) のような時系列データを扱うことは困難だからである (守 2001)。そこで, Elman はエルマンネット (単純再帰ネットワーク) を考案した。

エルマンネットの特徴は, 入力層 (input units) と出力層 (output units) の間で内的表層を形成する隠れ層 (hidden units) の状態を一時的に保持する文脈層 (context units) を配していることである。そのため信号を入力すると, その1つ前の信号が入力されたときの隠れ層の状態を保持していた文脈層からの情報も隠れ層に入ってくるので, 隠れ層には新しく入力された情報と文脈層からの情報とが混在することになる。この仕組みを利用することで, 同じ信号 (例: B) を入力しても, 1つ前に入力された信号が A であれば AB, A' であれば A'B というように隠

れ層において区別できるようになる (Figure 1 を参照)。




Figure 1. エルマンネットの構造

(Plunkett & Elman (1997: 152) をもとに作成)

加えて、エルマンネットでは出力として求められているものもパーセプトロン型のネットワークとは異なる。つまり、特定の入力に対応するパターンを出力として求めるのではなく、次に来る入力を予測させるのである。先述の Elman の例で言えば、関係代名詞 (例: *who*) が入力された場合は、1 つ前に入力された信号が *boy* であれば出力として *lives* (のような三人称単数の主語に対応する動詞) を、*boys* であれば *live* (のような三人称複数の主語に対応する動詞) を予測させることになる。シミュレーションでは、項目 (単語) ごとに出力層のユニットを割り当てて、各ユニットの活性値を比較し、活性値が大きい項目ほど次の入力として出てくる確率が高いと判断する。Elman (1991) では、エルマンネットを用いて英語の関係詞節を含んだ複文構造を学習させた。学習完了後、結合強度を固定し、それぞれの単語に該当する出力層のユニットの活性値を調べたところ、“*boys who Mary*” の順で入力した場合は、単数主語に対応する他動詞のみに活性化が見られた。これはネットワークが *boys* を先行する目的語として認識していることを意味する。また “*boys who Mary chases*” の順で入力した場合には、他動詞 *chases* の目的語と

なる名詞の活性化は見られず、複数主語に対応する動詞にのみ活性化が見られた。これはネットワークが先行する *boys* を *chases* の目的語として認識できているばかりでなく、そこで関係詞節が終わって、次に主節の動詞が続くことまで認識できていることを示している。

1.3 Rohde & Plaut (1999)

Elman (1991) では、先述の通り関係詞節を含んだ複文構造をネットワークに学習させることに成功したが、その際、段階的な学習が必要となることを主張している。予備実験で、単文と複文について段階を考慮せず一度に学習させたのでは学習が達成されることが分かったため、本実験では、学習を次のような 4 段階に分けてトレーニングを行った。まず、第 1 段階では、関係詞節を含まない単文のみ 10,000 文をネットワークに学習させた。第 2 段階では、10,000 文のうちの 1/4 が関係詞節を含む複文、残りの 3/4 を単文とした。続く第 3 段階では、単文と複文の割合がちょうど半々になるようにし、第 4 段階では、3/4 が関係詞節を含む複文、1/4 を単文とした。それぞれの段階が 5 回繰り返され、各段階 50,000 文ずつ、計 200,000 文を学習させた。その結果、学習が達成されたため、Elman は段階を踏んでトレーニングをすることが必要であると主張した (守 2001)。

これに対し、Rohde and Plaut (1999) は、意味論的な制約を用いれば、そのような段階的な学習によるインプットの制限は必要ないと主張している。Elman (1991) では、シミュレーションでのトレーニングにおいて “Mary chases Mary.” “Dogs walk.” “Boys bark.” のように文法的には正しくても意味的には不自然な文が同列に提示されていた。そこで、Rohde たちは、トレーニングにおいて、そのような意味的に不自然な文を除外する意味論的な制約を付加したところ、段階的な学習を行わなくても学習が可能となることを示した (Shirai 2019)。

2. 研究の目的

2.1 難易度の再解釈と意味論的要素の除外

Elman (1991) では、難易度を設定する際、提示する文における単文・複文の割合で調整していた。しかし、提示する文が単文か複文かのみ

基準では、主節の目的語に関係詞がつく場合、主節の主語に関係詞がつく場合、主節の主語と目的語の両方に関係詞がつく場合の区別ができない。主語に関係詞がつく場合は、主節の主語と動詞の間に従属節が入るため、文の構造上、主節の目的語に関係詞がつく場合よりも複雑さが増すと考えられる。さらに、主語と目的語のどちらにも関係詞節がつく場合は、より構造が複雑になるため、難易度が一層高くなることは明らかである。そのため、文の構造の複雑さによって難易度を設定した方がよいのではないかと考えた。

また、Rohde and Plaut (1999) では、意味論的な制約を考慮することで、段階的ではなくランダムに文を提示しても学習が達成されることを示したが、意味論的な要素を除外した場合については明らかにしていない。Elman (1991) と Rohde and Plaut (1999) のどちらにおいても、トレーニングの際に提示する文では具体的な単語 (Mary, dogs, walk, chase, 等) が用いられていたため、意味論的な要素が関わっていた。もし、そのような意味的な要素を除外したならば、段階的な学習が必要になるかもしれない。

2.2 リサーチ・クエスチョン

そこで、本研究では、単文と複文の割合ではなく、文の構造の複雑さによって難易度を設定し、また、意味論的な要素を除外するため、提示文では、具体的な単語ではなく、記号化した品詞 (S, Vi, Vt, O, 等) を用いてシミュレーションを実施する。こうした場合、段階的な学習が必要になるかどうかを検証し、考察していく。

3. 実験 I

3.1 変換フォーマットの作成

Elman (1991) や Rohde and Plaut (1999) では提示文に具体的な単語を用いていたが、本研究では意味論的な要素を除外するため、記号化した品詞を用いてシミュレーションを行う。当該の品詞として、“S” (主語)、“Vi” (自動詞)、“Vt” (他動詞)、“O” (目的語)、“R” (関係詞) の5つ、さらに文末記号として“.” (ピリオド)を加えた6つの記号を用いた。その際、主語と目的語 (になる名詞) については単数・複数の

区別をしていないため, Elman (1991) や Rohde and Plaut (1999) での学習課題にあった単数主語 (目的語の場合は, それが主格の関係詞の先行詞となる場合が相当) に対応する動詞の使い分け (三単現の -s の有無) が, 本研究では学習の対象から外れている。上述の 6 つの記号を以下のように 6 ビットでコード化する (Table 1 を参照)。

Table 1. コード変換表

記号 (品詞)	コード
S (主語)	1 0 0 0 0 0
Vi (自動詞)	0 1 0 0 0 0
Vt (他動詞)	0 0 1 0 0 0
O (目的語)	0 0 0 1 0 0
R (関係詞)	0 0 0 0 1 0
. (ピリオド)	0 0 0 0 0 1

3.2 シミュレータ

本研究では, Plunkett たちによって開発された “tlearn” を用いてシミュレーションを行う。この tlearn は, Windows や Mac といった汎用性の高い OS 上で動作し, 操作方法についても Plunkett & Elman (1997) や McLeod, Plunkett & Rolls (1998) などのマニュアルに詳しく説明されている。

3.3 ネットワークの設定

tlearn を用いてシミュレーションを実施するには, ネットワークの構成を設定する設定ファイル (configuration file), ネットワークに提示する入力信号を設定する入力信号ファイル (data file), 個々の入力信号に対する正しい出力を設定する教師信号ファイル (teach file) の計 3 種類のファイルを作成しなければならない。

本研究では, 入力, 出力ともに 6 ビットで信号を特定するため, 設定ファイルでネットワークの入力層と出力層をそれぞれ 6 ユニットになるように設定している。また, 隠れ層と文脈層のユニット数についてはそ

それぞれ 10 ユニットとした。(設定ファイルでの項目ごとの設定の詳細については Figure 2 を参照)

```

NODES:
nodes = 26
inputs = 6
outputs = 6
output nodes are 11-16
CONNECTIONS:
groups = 0
1-16 from 0
1-10 from i1-i6
1-10 from 17-26
11-16 from 1-10
17-26 from 1-10 = 1. & 1. fixed one-to-one
SPECIAL:
linear = 17-26
weight_limit = 0.1
selected = 1-10

```

Figure 2. 設定ファイルでの入力内容(実験 I)

入力層にはコード化された品詞を表象する信号が、それぞれ一つずつ提示され、出力層での出力と教師信号との差に基づいて、適切なコードが出力されるようユニット間の結合強度と各ユニットの閾値を調整していく。本研究では、先述の“S”, “Vi”, “Vt”, “O”, “R”, “.” の 6 つの記号を組み合わせる構成される 20 の文をネットワークに学習させる。これらの文は、文構造の複雑さに応じて 4 段階に分かれており、段階ごとに入力信号ファイルを作成する (Table 2 を参照)。

第 1 段階では①と②の 2 種類の単文がトレーニングの対象となるが、①の文を表すには 3 つの記号 (S と Vi と.) が使われているので 3 回の信号提示 (sweep という) が必要となる。この 3 sweeps が 1 セットとなる。②の文については 4 つの記号 (S と Vt と O と.) が使われているので、4 sweeps が 1 セットとなる。そのため、第 1 段階の入力信号ファイルでは① (3 sweeps) と② (4 sweeps) それぞれに対し 10 セットずつ (計 70 sweeps) を用意する。第 2 段階では、第 1 段階の 2 種類の単文に、主節の目的語に関係詞節が付く複文 (全 3 種) を追加し、それぞ

Table 2. 入力信号 (教師信号) データに含まれる構文の種類と試行回数

難易度	構文の区分	構文の種類	段階あり				段階なし
			第1段階	第2段階	第3段階	第4段階	
第1段階	単文 (全2種)	① SVi.	10回	10回	10回	10回	10回
		② SVt0.	10回	10回	10回	10回	10回
第2段階	主節の目的語に関係詞節 が付く複文 (全3種) を 追加	③ SVt0RVi.		10回	10回	10回	10回
		④ SVt0RVt0.		10回	10回	10回	10回
		⑤ SVt0RSVt.		10回	10回	10回	10回
		⑥ SRVivt.			10回	10回	10回
第3段階	主節の主語に関係詞節が 付く複文 (全6種) を 追加	⑦ SRVivt0.			10回	10回	10回
		⑧ SRVt0Vi.			10回	10回	10回
		⑨ SRVt0Vt0.			10回	10回	10回
		⑩ SRSVtVi.			10回	10回	10回
		⑪ SRSVtVt0.			10回	10回	10回
		⑫ SRVivt0RVi.					10回
第4段階	主節の主語と目的語の両 方に関係詞節が付く複文 (全9種) を追加	⑬ SRVivt0RVt0.				10回	10回
		⑭ SRVivt0RSVt.				10回	10回
		⑮ SRVt0Vt0RVi.				10回	10回
		⑯ SRVt0Vt0RVt0.				10回	10回
		⑰ SRVt0Vt0RSVt.				10回	10回
		⑱ SRSVtVt0RVi.				10回	10回
		⑲ SRSVtVt0RVt0.				10回	10回
		⑳ SRSVtVt0RSVt.				10回	10回

れの文を 10 セットずつ (計 270 sweeps) で入力信号ファイルを用意する。第 3 段階の入力信号ファイルでは、第 2 段階までの 5 種に、主節の主語に関係詞節が付く複文 (全 6 種) を追加し、それぞれの文を 10 セットずつ (計 640 sweeps) 用意する。第 4 段階では、第 3 段階までの 11 種に、主節の主語と目的語の両方に関係詞節が付く複文 (全 9 種) を追加し、それぞれの文を 10 セットずつ (計 1,480 sweeps) 用意する。作成した入力信号ファイルでは、これらのセットがランダムに配置されており、このファイルを 1 巡 (1 epoch という) すると、各文に対し 10 回ずつトレーニングを行ったことになる。

また、これらの入力に対応する適切な出力を設定する教師信号ファイルについては、次に来る入力の正しい予測を出力として求めているため、入力信号ファイルの先頭の行を最後の行に移動することにより作成する。

3.4 手続き

本研究では、段階的な学習を模擬する。各段階において、先述の各文について 15,000 回のトレーニングを行う。sweeps に換算すると、第 1 段階では 105,000 sweeps になる。第 2 段階では、トレーニング実行の際のオプション設定 (Training Options) で、第 1 段階終了時点でのユニット間の結合強度を呼び出し、そこを起点として新たに第 2 段階の入力信号ファイルでトレーニング (405,000 sweeps) を行うことで段階的な学習を模擬する。続く第 3 段階では、第 2 段階終了時点 (延べ 510,000 sweeps) での結合強度を呼び出し、そこを起点として新たに第 3 段階の入力信号ファイルでトレーニング (960,000 sweeps) を行い、第 4 段階では、第 3 段階終了時点 (延べ 1,470,000 sweeps) での結合強度を呼び出し、そこを起点として新たに第 4 段階の入力信号ファイルでトレーニング (2,220,000 sweeps) を行う。

また、段階を経ずに最初から第 4 段階の入力信号ファイルを用いて学習させるシミュレーションについても併せて実施し、これらの学習達成の結果を比較することで段階的な学習の必要性について検証する。その際、先の段階的な学習をしたシミュレーションでは、第 1 段階で導入した 2 文は、第 4 段階終了時点では各文 60,000 回の試行をしたことになる。そこで、この段階的な学習をしないシミュレーションでは、第 4 段

階の入力信号ファイルを使用して、各文 60,000 回に相当する 8,880,000 sweeps のトレーニングを実施する。

`tllearn` を用いたシミュレーションの具体的な手順としては、まず前節で設定したネットワークの設定ファイルと個々の段階に応じた入力信号ファイルおよびそれに対応する教師信号ファイルを指定して、トレーニングを実行するためのプロジェクトファイルを作成する。先述のトレーニング実行の際のオプション設定で、第 2 段階以降、前段階終了時点でのユニット間の結合強度を呼び出す他にも設定が必要な項目として、ユニット間の初期結合強度をランダムに割り振るランダムシード (random seed) の値を入力する (本研究では「602」とした)。また、このランダムシードに対し、適当な学習率 (learning rate) と慣性項 (momentum) も設定する (本研究では学習率を「0.2」、慣性項を「0.4」とした)。これらの値を統一することにより、特定の被験者を想定することができる。エルマンネットでは入力信号の提示順序は決まっているため、入力信号の提示方法については“Train Sequentially”を選択する。

3.5 分析手法

各段階でのトレーニングが終了した時点で、学習の達成状況について分析する。エルマンネットにおける出力は、学習の対象とした文について、その構成要素 (品詞の記号) を入力した時に、後に続く正しい要素を出力 (予測) できているかによって検証する。²

`tllearn` には、0 か 1 の二値で出力された信号のパターンを当該の構成要素 (本研究では品詞の記号) に変換してくれる翻訳機能が備わっている。この機能を活用して正しい要素を予測できているかを見ていくわけであるが、その際、留意すべき点として、正解が複数にまたがる場合がある。例えば、S の後に Vt や R が出力された場合、教師信号が Vi であったとしても、Vt や R でも文法的には正しいため、正解とみなすことができる。但し、S の後に O やピリオドが出力された場合は、文法的に正しくないため不正解となる。

² 実際のテストでは、検証用ファイルを 2 周走らせた結果について分析を行う。これは、ネットワークが課題を認識するための助走として 1 周走らせた後、2 周目の出力を見ることで、より課題に則した結果を得るためである。

3.6 結果と考察

Table 3 は、段階的な学習をしたシミュレーション（シミュレーションⅠ）と段階的な学習をしなかったシミュレーション（シミュレーションⅡ）の結果をまとめたものである。この表では、文を構成する出力記号全てが教師信号と一致する場合には「○」で示し、教師信号とは異なるが文法的に許容される記号が出力された場合には当該の記号に薄い網掛けを施し、文法的に正しくない記号が出力された場合には誤りとして当該の記号を太字にして下線を引き、濃い網掛けが施してある。

この表が示すように、シミュレーションⅠについては第1段階から第2段階までは学習を達成できたが、第3段階で1か所で誤りが出て、続く第4段階では8か所で誤りが確認された。全体で見ると9か所で誤りが確認された。また、シミュレーションⅡについても学習を達成することができなかった。誤りの出現個所を見ると14か所で誤りが確認された。

今回のシミュレーションの結果から、文構造の複雑さによる難易度（段階）の設定については、段階が上がるごとに誤りの数が増えているので設定は支持されたと考えられる。一方、段階的な学習の必要性については、段階を考慮しない場合よりも誤りの数は少なかったが、学習を最終段階まで達成することはできなかった。そこで、本研究では処理能力の向上を目指してエルマンネットを修正し、再度検証を行うことにした。

4. 実験Ⅱ

4.1 ACC を想定した修正エルマンネット

石崎・中村（2019, 2020）は、バイリンガルを想定してエルマンネットに日本語と英語を学習させたが、学習を達成させることができなかった。そこで、もともとコネクショニズムは脳における神経細胞のネットワークをモデルにしているため、バイリンガルの脳に関する研究に解決の糸口を求めた。バイリンガルの脳の神経画像研究を行った Abutaleb & Green (2008) によると、バイリンガルが1つの言語で話そうとする場合、もう1つの言語を使おうとする衝動を ACC (anterior cingulate cortex, 前帯状皮質) が抑制していること、またその当該言語をいつどのように使うのかという意志決定を絶えず行っていることが明らかになった。そこで、石崎・中村は、この ACC を想定した部位をエルマンネ

Table 3. シミュレーションⅠ及びシミュレーションⅡにおけるテストタイミング結果(実験Ⅰ)

入力 (構文の種類)	シミュレーションⅠ				シミュレーションⅡ
	第1段階	第2段階	第3段階	第4段階	
① SVi.	O	S Vt.	S R.	S R.	段階なし S R.
② SVtO.	SVi O.	S Vt O R	S R O R	S R O R	S R O R
③ SVtORVi.	/	S Vt O R S.	S R O R Vt.	S R O R Vt.	S R O R S.
④ SVtORVtO.	/	S Vt O R S O.	S R O R Vt O.	S R O R Vt O Vt	S R O R S O Vt
⑤ SVtORSVt.	/	S Vt O . S Vt .	S R O R Vt Vt .	S R O R Vt Vt Vt	S R O R S Vt .
⑥ SRViVi.	/	/	S R Vt Vt .	S R Vt Vt .	S R S .
⑦ SRViVtO.	/	/	S R Vt Vt O .	S R Vt Vt O R	S R S O R
⑧ SRVtOVi.	/	/	S R S O Vt .	S R Vt O Vt .	S R Vt O Vt .
⑨ SRVtOvO.	/	/	S R Vt O . O .	S R Vt O Vt O R	S R S O Vt O R
⑩ SRSVtVi.	/	/	S R Vt Vt Vt .	S R Vt Vt Vt .	S R S Vt .
⑪ SRSVtVtO.	/	/	S R Vt Vt Vt O .	S R Vt Vt Vt O R	S R S Vt . O R
⑫ SRViVtORVi.	/	/	S R Vt Vt O R Vt .	S R Vt Vt O R Vt .	S R S . O R S .
⑬ SRViVtORVtO.	/	/	S R Vt Vt O R Vt O Vt .	S R Vt Vt O R Vt O Vt	S R S . O R S O Vt
⑭ SRViVtORSVt.	/	/	S R Vt Vt O R Vt Vt Vt	S R Vt Vt O R Vt Vt Vt	S R S . O R S Vt .
⑮ SRVtOvORVi.	/	/	S R Vt O Vt O R Vt .	S R Vt O Vt O R Vt .	S R S O Vt O R S .
⑯ SRVtOvORVtO.	/	/	S R Vt O Vt O R Vt O Vt .	S R Vt O Vt O R Vt O Vt	S R S O Vt O R S O Vt
⑰ SRVtOvtORSVt.	/	/	S R Vt O Vt O R Vt Vt Vt	S R Vt O Vt O R Vt Vt Vt	S R S O Vt O R S Vt .
⑱ SRSVtVtORVtO.	/	/	S R Vt Vt O R Vt O Vt .	S R Vt Vt O R Vt O Vt	S R S Vt . O R S O Vt
⑳ SRSVtVtORSVt.	/	/	S R Vt Vt O R Vt Vt Vt	S R Vt Vt O R Vt Vt Vt	S R S Vt . O R S Vt .

ットに組み込むことにした。具体的には、文脈層から独立した隠れ層のユニットを新たに設けることにより、これらのユニットが出力に影響を及ぼすことで ACC の役割を果たすことを期待した (Figure 4 の囲みの部分が該当)。この ACC を想定した修正エルマンネットを用いてバイリンガルの学習を模擬したところ、学習を達成することができた。




Figure 4. ACC を想定した修正エルマンネットの構造

4.2 ネットワークの設定

本研究においても、エルマンネットの処理能力向上を期待して、この ACC を想定した機能を、実験 I で構築した tlearn 上のネットワークに組み込むことにした。設定ファイル上の修正としては、隠れ層のユニット数を 10 から倍の 20 に増やし、前半の 10 ユニットは文脈層とは関連付けず、後半の 10 ユニットのみを文脈層と関連付けた。このことにより、文脈層から独立した前半の 10 ユニットの隠れ層が ACC の役割を担うことを想定した (他の項目の設定については Figure 5 を参照)。

4.3 手続きと分析手法

実験 I の結果と比較するため、実験 II でも実験 I と同様のランダムシード、学習率、慣性項を用いて同一の被験者を想定する。また、手続き

についても、実験 I と同様の入力信号ファイルと教師信号ファイルを用いて同様の手法により実施する。トレーニング実施後の分析についても、実験 I と同様の手法を用いる。

```
NODES:
nodes = 36
inputs = 6
outputs = 6
output nodes are 21-26
CONNECTIONS:
groups = 0
1-26 from 0
1-20 from i1-i6
11-20 from 27-36
21-26 from 1-20
27-36 from 11-20 = 1. & 1. fixed one-to-one
SPECIAL:
linear = 27-36
weight_limit = 0.1
selected = 1-20
```

Figure 5. 設定ファイルでの入力内容(実験 II)

4.4 結果と考察

Table 4 が示すように、段階的な学習をしたシミュレーション I については、第 1 段階では学習を達成できたが、第 2 段階で 1 か所、第 3 段階でも 1 か所、第 4 段階で 5 か所の誤りが確認された。また、段階的な学習をしなかったシミュレーション II についても学習を達成することができなかった。

今回のシミュレーションの結果、シミュレーション I と II のどちらにおいても学習を最終段階まで達成することはできなかった。そればかりかシミュレーション I では、実験 I で学習が達成していた第 2 段階においても誤りが出てしまった。石崎 (2011) によると、ACC は感覚的処理に対するモニターであるため、日本語と英語の使い分けのような言語に依存した領域固有の課題については適応するが、今回のように高次の認知的処理を要する領域非固有の課題については ACC による機能介入は適さなかったのかもしれない。

Table 4. シミュレーション I 及びシミュレーション II におけるテストティング結果(実験 II)

入力 (構文の種類)	シミュレーション I				シミュレーション II
	第 1 段階	第 2 段階	第 3 段階	第 4 段階	
① SVi.	O	S Vt .	S R .	S R .	段階なし S R .
② SVtO.	S V i O .	S V t O R	S V t O R	S R O R	S R O R
③ SVtORVi.		S V t O R S .	S R O R V t .	S R O R S .	S R O R V t .
④ SVtORVtO.		S V t O R V i O .	S V t O R V t O R	S R O R V t O V t	S R O R V t O V t
⑤ SVtORSVt.		S V t O R S V t S	S R O R V t V t V i	S R O R S V t V t	S R O R V t V t .
⑥ SRVivi.			S R V i V t .	S R V t V t .	S R S V t .
⑦ SRVivtO.			S R S V t O .	S R V t V t O R	S R S V t O R
⑧ SRVtOVi.			S R S O V t .	S R V t O V t .	S R V t O V t .
⑨ SRVtOvtO.			S R S O V t O .	S R V t O V t O R	S R S O V t O R
⑩ SRSVtVi.			S R S V t V t .	S R V t V t V t .	S R V t V t V i .
⑪ SRSVtVtO.			O	S R V t V t V t O R	S R V t V t V i O V t
⑫ SRVivtORVi.				S R V t V t O R S .	S R V t V t O R V t .
⑬ SRVivtORVtO.				S R V t V t O R S O .	S R V t V t O R V t O V t
⑭ SRVivtORSVt.				S R V t V t O R S V t O	S R V t V t O R V t V t .
⑮ SRVtOvtORVi.				S R V t O V t O R V t .	S R S O V t O R V t .
⑯ SRVtOvtORVtO.				S R V t O V t O R V i O .	S V t V t O V t O R V t O .
⑰ SRVtOvtORSVt.				S R V t O V t O R V i V t V t	S R V t O V t O R V t V t .
⑱ SRSVtVtORVi.				S R V t V t V t O R V t .	S R S V t V i O V t V i .
⑲ SRSVtVtORVtO.				S R V t V t V t O R V t O .	S V t V t V t V i O V t V i O .
⑳ SRSVtVtORSVt.				S R V t V t V t O R V t V t V t	S R V t V t V i O V t V i V t .

5. 実験Ⅲ

5.1 DLPFC を想定した修正エルマンネット

石崎 (2011) によると, 感覚的処理を経た後, 注意を向けられた情報に対して行われるのが高次の認知的処理で, そのモニターの役割を担っているのが DLPFC (dorsolateral prefrontal cortex, 背外側前頭前野) である。今回の課題のような非常に複雑な文構造の処理については, ACC よりも DLPFC の方が適していると考え, この DLPFC を想定したモニター機能をネットワークに付加することにした。具体的には, DLPFC を想定したモニター機能が作動記憶に関わる隠れ層や文脈層を経由した情報に対して働くように, 隠れ層から出力層へとつながる新たな層をネットワークに付加することで設定した (Figure 7 の囲みの部分が該当)。




Figure 7. DLPFC を想定した修正エルマンネットの構造

5.2 ネットワークの設定

実験Ⅰで構築したネットワークに DLPFC を想定した機能を組み込むための `tlearn` の設定ファイル上での修正としては, 入力層から接続される隠れ層の他に 10 ユニットから成る別の隠れ層を設け, この隠れ層を経由せず直接に出力層へとつながる結合とこの隠れ層を経由して出力層

へとつながる結合の 2 チャンネルの流れを作った。こうすることによって、この新たに設けた隠れ層が、作動記憶に関わる文脈層を経由した従前の隠れ層からの情報に対するモニターとして働くことを想定した（他の項目の設定については Figure 8 を参照）。

```

NODES:
nodes = 36
inputs = 6
outputs = 6
output nodes are 21-26
CONNECTIONS:
groups = 0
1-26 from 0
1-10 from i1-i6
1-10 from 27-36
11-20 from 1-10
21-26 from 1-20
27-36 from 1-10 = 1. & 1. fixed one-to-one
SPECIAL:
linear = 27-36
weight_limit = 0.1
selected = 1-20

```

Figure 8. 設定ファイルでの入力内容(実験Ⅲ)

5.3 手続きと分析手法

これまでの結果と比較するため、実験Ⅲでもこれまでと同様のランダムシード、学習率、慣性項を用いて同一の被験者を想定する。また、手続きについても、これまでと同様の入力信号ファイルと教師信号ファイルを用いて同様の手法により実施する。トレーニング実施後の分析についても、これまでと同様の手法を用いる。

5.4 結果と考察

Table 5 が示すように、段階的な学習をしたシミュレーションⅠについては、最終段階まで学習を達成することができた。一方、段階的な学習をしなかったシミュレーションⅡについては学習を達成することができなかった。誤りの出現個所については 4 か所で誤りが確認された。

Table 6. シミュレーションⅠ及びシミュレーションⅡにおけるテストティング結果 (実験Ⅲ)

入力 (構文の種類)	シミュレーションⅠ				シミュレーションⅡ
	第1段階	第2段階	第3段階	第4段階	
① SVi.	O	S Vt.	S R.	S R.	段階なし S R.
② SVtO.	S Vi O.	S Vt O R	S Vt O R	S R O R	S R O R
③ SVtORVi.	/	S Vt O R Vi.	S R O R Vt.	S R O R Vt.	S R O R S.
④ SVtORVtO.	/	S Vt O R Vt O.	S Vt O R S O.	S R O R S O.	S R O R S O Vt.
⑤ SVtORSVt.	/	S Vt O R Vi Vt.	S R O R Vt Vt.	S R O R Vt Vt.	S R O R S Vt.
⑥ SRViVi.	/	/	S R Vi Vt.	S R Vt Vt.	S R Vt Vt.
⑦ SRViVtO.	/	/	S R Vt Vt O.	S R Vt Vt O R	S R S Vt O R
⑧ SRVtOVi.	/	/	S R Vt O Vi.	S R S O Vt.	S R Vt O Vt.
⑨ SRVtO VtO.	/	/	S R Vt O Vi O.	S R Vt O Vt O R	S R Vt O Vt O R
⑩ SRSVtVi.	/	/	S R Vt Vt Vt.	S R Vt Vt Vt.	S R Vt Vt Vt.
⑪ SRSVtVtO.	/	/	S R Vt Vt Vt O.	S R Vt Vt Vt O R	S R Vt Vt Vt O R
⑫ SRViVtORVi.	/	/	/	S R S Vt O R Vt.	S R Vt Vt O R S.
⑬ SRViVtORVtO.	/	/	/	S R S Vt O R Vt O.	S R Vt Vt O R S O Vt.
⑭ SRViVtORSVt.	/	/	/	S R Vt Vt O R Vt Vt.	S R S Vt O R S Vt.
⑮ SRVtO VtORVi.	/	/	/	S R Vt O Vt O R S.	S R Vt O Vt O R S.
⑯ SRVtO VtORVtO.	/	/	/	S R S O Vt O R S O.	S R Vt O Vt O R S O Vt.
⑰ SRVtO VtORSVt.	/	/	/	O	S R S O Vt O R S Vt.
⑱ SRSVtVtORVi.	/	/	/	S R Vt Vt Vt O R Vt.	S R Vt Vt Vt O R S.
⑲ SRSVtVtORVtO.	/	/	/	O	S R Vt Vt Vt O R S O Vt.
⑳ SRSVtVtORSVt.	/	/	/	S R Vt Vt Vt O R Vt Vt.	O

ネットワークに DLPFC を想定した機能を組み込んだ結果、段階的な学習をしたシミュレーション I において、初めて全ての段階の学習を達成することができた。このことから、今回の学習課題のような高次の認知的処理を要する学習においては、DLPFC によるモニター機能が必要になることが示唆された。

また、段階的な学習をしなかったシミュレーション II においては、ネットワークに DLPFC を想定した機能を組み込んで最終段階まで学習を達成することができなかった。このことから、今回の学習課題のような高次の認知的処理を要する学習においては、DLPFC によるモニター機能だけでなく、段階的な学習も必要であることが示唆された。

6. 今後の課題

本研究でのシミュレーションの結果から、まず文の構造の複雑さによって設定した難易度については、段階が上がるごとに誤りの数が増えていく傾向が見られたことから、文の構造の複雑さによる難易度の設定は支持されたと言える。また、今回のような高次の認知的処理を要する学習においては、意味論的な要素を除外した場合、段階的な学習が必要であることもわかった。その際、段階的な学習だけでは不十分であり、DLPFC を想定したモニター機能をネットワークに付加することも必要であることが確認された。今後の課題として、このことをさらに検証するため、DLPFC のモニター機能を付加したネットワークを用いて石崎・中村 (2019, 2020) のバイリンガルによる学習シミュレーションを実施する予定である。

本研究における役割分担について

本研究における役割分担としては、研究のフレームと実験の指導を石崎が担当し、実験の実施と分析については菅原が担当した。また、実験の計画立案と結果の考察については両方で相談しながら実施した。論文の執筆に当たっては、まず菅原が素案を作成し、それを基に石崎が原稿を執筆して、その後、互いに校閲を行った。

参考文献

- 石崎貴士 (2011) 『感覚的処理と認知的処理から成る言語情報処理モデルの検証：応用言語学的観点からの考察』 博士論文 (東北大学) .
- 石崎貴士・中村江里 (2019) 「コネクショニズムを応用したバイリンガル研究：ACC を想定した修正エルマンネットによる検証」, 『山形英語研究』 第 16 号, 13-34.
- 石崎貴士・中村江里 (2020) 「ACC を想定した修正エルマンネット：その適用可能性についての追検証」, 『山形大学大学院教育実践研究科年報』 第 11 号, 16-24.
- 守 一雄 (1996) 『やさしい PDP モデルの話：文系読者のためのニューラルネットワーク理論入門』, 新曜社.
- 守 一雄 (2001) 「単純再帰ネットワーク (エルマンネット) による文法の獲得」 守一雄・都築 誉史・楠見 孝 (編) 『コネクショニストモデルと心理学：脳のシミュレーションによる心の理解』, 北大路書房.
- Abutalebi, J., & Green, D. W. (2008) Control mechanisms in bilingual language production: Neural evidence from language switching studies. *Language and Cognitive Processes*, 23, 557-582.
- Elman, J. L. (1991) Distributed representations, simple recurrent networks, and grammatical structure. *Machine Learning*, 7, 195-225.
- McLeod, P., Plunkett, K. & Rolls, E. T. (1998) *Introduction to Connectionist Modeling of Cognitive Processes*. Oxford: Oxford University Press.
- Plunkett, K., & Elman, J. L. (1997) *Exercises in Rethinking Innateness*. Cambridge, MA: MIT Press.
- Rohde, D. L. T., & Plaut, D. C. (1999) Language acquisition in the absence of explicit negative evidence: How important is starting small? *Cognition*, 72, 67-109.
- Rumelhart, D. E. & McClelland, J. L. (1986) On learning the past tenses of English verbs. In D. E. Rumelhart, J. L. McClelland & the PDP Research Group (Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. 2 (pp. 216-271). Cambridge, MA: MIT Press.
- Shirai, Y. (2019) *Connectionism and Second Language Acquisition*, New York, NY: Routledge.