

# 回答スタイルを制御可能な生成型機械読解

西田 京介<sup>1</sup> 齊藤 いつみ<sup>1</sup> 西田 光甫<sup>1</sup> 篠田 一聡<sup>2\*</sup> 大塚 淳史<sup>1</sup> 浅野 久子<sup>1</sup> 富田 準二<sup>1</sup>

<sup>1</sup>NTTメディアインテリジェンス研究所 <sup>2</sup>東京大学大学院 情報理工学系研究科

## 1 はじめに

近年、質問にテキストを読み解いて答える機械読解が注目を集めている。従来はSQuAD [12, 13]に代表される、テキストから回答範囲の始点と終点を予測する抽出型機械読解が主に取り組まれてきた。その一方で、回答をテキストの範囲に限定しない生成型機械読解は、重要な研究課題であるにも関わらず十分な成果が得られていない。BERT [3]などの抽出モデルでは任意の回答を生成できず、従来の生成モデル [20, 8]は学習データ量の不足が課題となっている。

また、機械読解を実用化に向けて発展させるためには、同一の質問に対して複数のスタイルで回答する能力の実現が重要と考える。特に、Web 検索に適したフレーズによる簡潔な回答や、SiriやAlexaなどのスマートデバイスに適した自然文による回答の生成は需要が高い。これらの異なるスタイルに基づく学習は互いに補完する関係にあると考えられるが、複数スタイルの同時学習、さらには回答文生成の制御を行う機械読解の研究はこれまで行われていない。

本研究では、新たな生成型読解モデルMasqueを提案する。提案モデルは、Bing 検索結果の10パッセージから読解を行うMS MARCO 2.1 [2]において、回答スタイルが異なる2つのタスクにてstate-of-the-artの性能を達成した。主な貢献は以下の2点である。

1. 複数テキストの要約に基づく生成型読解。文書要約で用いられるpointer-generator [14]を語彙からの生成および質問・複数パッセージからのコピーが可能なモデルに拡張して生成型読解を実現した(図1)。さらにRNNからTransformer [21]ベースに拡張した。
2. 回答スタイルを制御可能な読解。pointer-generatorを回答スタイルを条件とした条件付デコーダに拡張し、複数スタイルの同時学習およびスタイルを指定した回答文生成を可能にした(図1)。

## 2 問題定義

本研究で取り組む生成型機械読解を定式化する。

**問題 1.** 質問  $x^q = \{x_1^q, \dots, x_j^q\}$ ,  $K$  個のパッセージ  $x^{p_k} = \{x_1^{p_k}, \dots, x_L^{p_k}\}$  ( $k = 1, \dots, K$ ), スタイル  $s$  を入力とする。機械読解システムはスタイルに応じた回答  $y = \{y_1, \dots, y_T\}$  を出力する。

すなわち、推論時は3つ組  $(x^q, \{x^{p_k}\}, s)$  を入力とし、 $P(y)$  を出力する。訓練データは6つ組  $(x^q, \{x^{p_k}\}, s, y, a, \{r^{p_k}\})$  とする。 $a$  は質問に対してパッセージ集合  $\{x^{p_k}\}$  の全体を基に回答可能な場合に1,  $r^{p_k}$  は第  $k$  パッセージ  $x^{p_k}$  が回答に必要な場合に1となるバイナリ変数である。

\*NTTにおけるインターンシップ期間中の貢献。

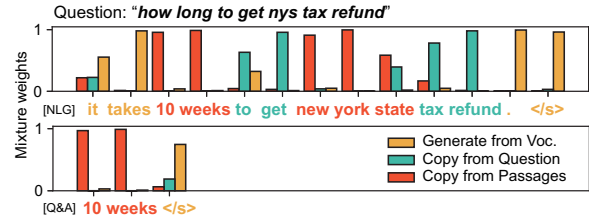


図1: 提案モデルによる回答文生成例。指定スタイル(上: 自然言語生成, 下: 簡潔な回答)に応じて、語彙からの生成および質問・パッセージからのコピーに基づく確率分布を生成ステップ毎に混合して生成する。

## 3 提案モデル

Masque は条件付確率  $p(y|x^q, \{x^{p_k}\}, s)$  の end-to-end モデルである。複数スタイルの同時学習に加えて、機械読解のさらなる精度向上のため、回答に必要なパッセージのランキングと回答可否の分類をマルチタスク学習する。図2にアーキテクチャの全体図を示す。

### 3.1 質問・パッセージリーダー

入力  $x^q, \{x^{p_k}\}$  の文脈理解およびマッチングを行う。

#### 3.1.1 単語埋め込み層

事前学習により獲得された300次元GloVe [10]と512次元ELMo [11]の出力を連結して2層のhighway network [16]へ入力し、単語ベクトル系列を出力する。

#### 3.1.2 共有エンコーダ層

前層の出力を  $d$  次元に線形変換後、3層のTransformer [21]を作用させ、各パッセージに対して  $E^{p_k} \in \mathbb{R}^{d \times L}$ , 質問に対して  $E^q \in \mathbb{R}^{d \times J}$  を出力する。

**Transformer エンコーダブロック.** 各ブロックはself-attentionと2層のFFNから構成される。self-attentionはmulti-headアテンション(8ヘッド) [21]を用いる。各サブブロックの出力は入力を  $x$ , 処理を  $f$  としたとき、residual結合, layer normalization [1]を用いて  $\text{LayerNorm}(f(x) + x)$  とする。全てのサブブロックの入出力次元は  $d = 304$  とする。FFNの1層目の出力は256次元、活性化関数はGELU [4]とする。

#### 3.1.3 双対アテンション層

まず、質問と第  $k$  パッセージの類似度行列  $U^{p_k} \in \mathbb{R}^{L \times J}$  を求める。各行列要素は [15] と同様に

$$U_{ij}^{p_k} = w^a \top [E_i^{p_k}; E_j^q; E_i^{p_k} \odot E_j^q] \quad (1)$$

とする。 $w^a \in \mathbb{R}^{6d}$  は学習パラメータである。 $\odot$  はアダマール積,  $[\cdot]$  は行方向に沿ったベクトル連結の演算子を表す。次に、 $U^{p_k}$  を各行・各列で正規化し、 $A^{p_k} = \text{softmax}_j(U^{p_k \top}) \in \mathbb{R}^{J \times L}$ ,  $B^{p_k} = \text{softmax}_i(U^{p_k}) \in$

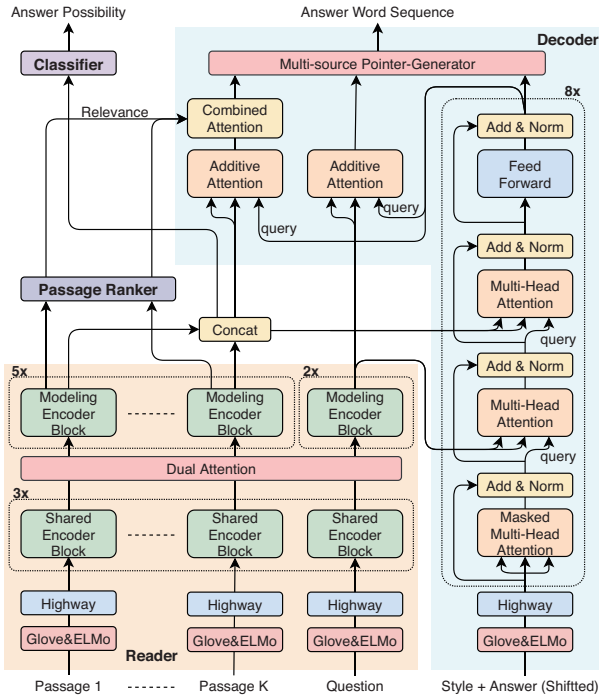


図 2: Masque モデルアーキテクチャ.

$\mathbb{R}^{L \times J}$  を得る. そして, DCN [23] により質問からパッセージへのアテンション  $G^{q \rightarrow pk} \in \mathbb{R}^{5d \times L}$ :

$$[E^{pk}; \bar{A}^{pk}; \bar{B}^{pk}; E^{pk} \odot \bar{A}^{pk}; E^{pk} \odot \bar{B}^{pk}]$$

パッセージから質問へのアテンション  $G^{p \rightarrow q} \in \mathbb{R}^{5d \times J}$ :

$$[E^q; \max_k(\bar{B}^{pk}); \max_k(\bar{B}^{pk}); E^q \odot \max_k(\bar{B}^{pk}); E^q \odot \max_k(\bar{B}^{pk})]$$

をそれぞれ得る. ここで,  $\bar{A}^{pk} = E^q A^{pk} \in \mathbb{R}^{d \times L}$ ,  $\bar{B}^{pk} = E^{pk} B^{pk} \in \mathbb{R}^{d \times J}$ ,  $\bar{A}^{pk} = \bar{B}^{pk} A^{pk} \in \mathbb{R}^{d \times L}$ ,  $\bar{B}^{pk} = \bar{A}^{pk} B^{pk} \in \mathbb{R}^{d \times J}$  である.

### 3.1.4 モデリングエンコーダ層

$G^{p \rightarrow q}$  から  $M^q \in \mathbb{R}^{d \times J}$ ,  $G^{q \rightarrow pk}$  から  $M^{pk} \in \mathbb{R}^{d \times L}$  をそれぞれ 2 層, 5 層の Transformer を作用させ得る.

## 3.2 パッセージランカー

各パッセージの適合度  $\beta^{pk}$  を出力する. 各パッセージの最初の単語 (BOS トークン) に対するモデリングエンコーダ層の出力をパッセージの表現とし,

$$\beta^{pk} = \text{sigmoid}(w^r \top M_1^{pk}) \quad (2)$$

を出力する.  $w^r \in \mathbb{R}^d$  は学習パラメータである.

## 3.3 回答可否分類器

質問に対して, 与えられた  $K$  個のパッセージを基に回答が可能である確率  $P(a=1)$  を出力する. 各パッセージの最初の単語 (BOS トークン) に対するモデリングエンコーダ層の出力を結合し,

$$P(a) = \text{sigmoid}(w^c \top [M_1^{p1}; \dots; M_1^{pK}]) \quad (3)$$

を出力する.  $w^c \in \mathbb{R}^{Kd}$  は学習パラメータである.

## 3.4 回答文デコーダ

自己回帰的に各ステップで生成した単語を次ステップの入力とする. 回答スタイルの制御のため, 回答文の BOS トークンをスタイル毎に用意したトークンに変更する. 推論時は, トークンの指定によりスタイルを制御できる. トークン制御は [6, 19] 等で実績があり, モデルアーキテクチャに変更を与えず制御を可能にする.

### 3.4.1 単語埋め込み層

リーダの単語埋め込み層と同様である. ただし, ELMo は双方向 LSTM の順方向分 (256 次元) のみを用いる.

### 3.4.2 アテンション付デコーダ層

スタイル+回答系列に対する単語埋め込み層の出力を  $d$  次元に線形変換後, 8 層の Transformer を用いて, デコーダ状態系列  $\{s_1, \dots, s_T\} \in \mathbb{R}^{d \times T}$  を出力する.

**Transformer デコーダブロック.** エンコーダブロックに 2 つのサブブロックを挿入する (図 2). self-attention 層は位置  $t$  において  $t+1$  以降の情報を考慮しない subsequent マスク [21] を利用する. 追加したサブブロックでは  $M^q$ ,  $M^{pall}$  を key, value とした multi-head アテンション (8 ヘッド) [21] を行う.  $M^{pall}$  はモデリングエンコーダ層の各パッセージに関する出力の連結  $M^{pall} = [M^{p1}, \dots, M^{pK}] \in \mathbb{R}^{d \times KL}$  である. ここで,  $[\cdot]$  は列方向のベクトル連結の演算子を表す.

### 3.4.3 複数情報源 Pointer-Generator

**拡張語彙分布.** 拡張語彙  $V_{\text{ext}}$  を GloVe の語彙  $V$  の上位 5,000 語と入力に出現する単語の和集合とする.  $t$  番目の回答単語  $y_t$  に対する  $V_{\text{ext}}$  上の確率分布  $P^v$  を

$$P^v(y_t) = \text{softmax}(W^2 \top (W^1 s_t + b^1)) \quad (4)$$

と定義する. ここで,  $W^2 \in \mathbb{R}^{d_{\text{word}} \times V_{\text{ext}}}$  は対応する GloVe の重みと一致させる [5].  $W^1 \in \mathbb{R}^{d_{\text{word}} \times d}$ ,  $b^1 \in \mathbb{R}^{d_{\text{word}}}$  は学習パラメータである. なお,  $y_t$  が  $V$  に含まれていない場合,  $P^v(y_t) = 0$  とする.

**コピー分布.** [14] では, 1 層の RNN デコーダの加法的アテンション分布をコピーのために利用する. これに対して, 提案モデルの 8 層の Transformer デコーダでは, ヘッド数分のアテンション分布が出力されるためコピー機構で用いるには適さない. そこで, 加法的アテンションを追加し, デコーダ状態  $s_t$  をクエリとして, 質問系列に対してアテンション分布  $\alpha_t^q \in \mathbb{R}^J$ , コンテキストベクトル  $c_t^q \in \mathbb{R}^d$ , パッセージ系列に対して  $\alpha_t^p \in \mathbb{R}^{KL}$ ,  $c_t^p \in \mathbb{R}^d$  をそれぞれ出力する.

$$\alpha_t^q = \text{softmax}(e^q), \quad c_t^q = \sum_j \alpha_{tj}^q M_j^q \quad (5)$$

$$\alpha_t^p = \text{softmax}([e^{p1}, \dots, e^{pK}]), \quad c_t^p = \sum_l \alpha_{tl}^p M_l^{pall} \quad (6)$$

ここで,  $e_j^q = w^q \top \tanh(W^{qm} M_j^q + W^{qs} s_t + b^q)$ ,  $e_l^{pk} = w^p \top \tanh(W^{pm} M_l^{pk} + W^{ps} s_t + b^p)$  とする.  $w^q$ ,  $w^p$ ,  $b^q$ ,  $b^p \in \mathbb{R}^d$ ,  $W^{qm}$ ,  $W^{qs}$ ,  $W^{pm}$ ,  $W^{ps} \in \mathbb{R}^{d \times d}$  は学習パラメータである. そして, 質問・パッセージからのコピー分布  $P^q$  と  $P^p$  を,  $\alpha_t^q$ ,  $\alpha_t^p$  に基づき

$$P^q(y_t) = \sum_{j: x_j^q = y_t} \alpha_{tj}^q, \quad P^p(y_t) = \sum_{l: x_l^{pk(l)} = y_t} \alpha_{tl}^p \quad (7)$$

と定義する.  $k(l)$  は, 結合パッセージの  $l$  番目の単語に対応するパッセージのインデックスを示す.

混合分布. 回答単語  $y_t$  の分布を, 式 (4), 式 (7) に示す 3 つの分布の混合分布として定義する.

$$P(y_t) = \lambda^v P^v(y_t) + \lambda^q P^q(y_t) + \lambda^p P^p(y_t), \quad (8)$$

$\lambda^v, \lambda^q, \lambda^p = \text{softmax}(W^m[s_t; c_t^q; c_t^p] + b^m)$  とする.  $W^m \in \mathbb{R}^{3 \times 3d}$ ,  $b^m \in \mathbb{R}^3$  は学習パラメータである.

### 3.4.4 結合アテンション

回答に無関係なパッセージから単語を生成しないために, 文書要約で用いられる文と単語レベルのアテンションを結合する手法 [17] を導入する. 提案モデルでは, パッセージレベルの適合度  $\beta^{pk}$  と単語レベルのアテンション  $\alpha_t^p$  を乗算し, 再正規化を行う.

$$\alpha_{tl}^p := \frac{\alpha_{tl}^p \beta^{pk(l)}}{\sum_{l'} \alpha_{tl}^p \beta^{pk(l')}} \quad (9)$$

## 3.5 損失関数

デコーダ, パッセージランカー, 回答可否分類器の損失を結合した  $L(\theta) = L_{\text{dec}} + \gamma_{\text{rank}} L_{\text{rank}} + \gamma_{\text{cls}} L_{\text{cls}}$  を最小化する. ここで,  $\theta$  はモデルパラメータであり,  $\gamma_{\text{rank}} = 0.5$ ,  $\gamma_{\text{cls}} = 0.1$  とした. デコーダの損失  $L_{\text{dec}}$  は回答文長で正規化した負の対数尤度により求める.

$$L_{\text{dec}} = -\frac{1}{N_{\text{able}}} \sum_{(a,y) \in \mathcal{D}} \frac{a}{T} \sum_t \log P(y_t) \quad (10)$$

ここで,  $\mathcal{D}$  は  $N$  個の訓練データ,  $N_{\text{able}}$  は  $a = 1$  の訓練データ数である. ランカー, 分類器の損失  $L_{\text{rank}}$ ,  $L_{\text{cls}}$  は 2 値のクロスエントロピーにより求める.

$$L_{\text{rank}} = -\frac{1}{NK} \sum_k \sum_{r^{pk} \in \mathcal{D}} \left( r^{pk} \log \beta^{pk} + (1 - r^{pk}) \log(1 - \beta^{pk}) \right) \quad (11)$$

$$L_{\text{cls}} = -\frac{1}{N} \sum_{a \in \mathcal{D}} \left( a \log P(a) + (1 - a) \log(1 - P(a)) \right) \quad (12)$$

## 4 評価実験

### 4.1 実験設定

データセットおよびスタイル. MS MARCO 2.1 [2] の **NLG**, **Q&A** タスクにより実験を行った. 回答スタイルは各タスクに対応させた. **NLG** タスクは質問とパッセージからの要約を生成して回答する (平均 16.6 単語). **Q&A** タスクも同様に要約を必要とするが, 回答の多数は質問の文脈を含まない簡潔な回答となる (平均 13.1 単語). 例えば, “tablespoon in cup” という質問に対して, Q&A タスクでは “16”, NLG タスクでは “There are 16 tablespoons in a cup.” が回答となる. また, 全データ **ALL** に加えて, 評価用に 2 つのサブセットを用意した (表 1). **ANS** は回答可能な質問, **WFA** は回答可能かつ NLG タスク用の回答で構成され,  $WFA \subset ANS \subset ALL$  の関係を満たす.

学習用設定. **ALL** セットを用いて, バッチサイズ 80, エポック数 8 とし, 8 枚の NVIDIA Tesla P100 GPU により学習した. デコーダへの入力には Teacher-forcing とした. モデルパラメータの指数移動平均 (係数 0.9995) を管理し, 推論時に用いた. アンサンブルモデルは 6 試行で構成した. spaCy を用いてトークナイズし, ELMo への入力を除いて小文字化した. 最適化には Adam を

set	train	dev.	eval
ALL	808,731	101,093	101,092
ANS	503,370	55,636	-
WFA	153,725	12,467	-

表 1: MS MARCO 2.1 のサブセットの QA ペア数.

Model	NLG		Q&A	
	Rouge-L	Bleu-1	Rouge-L	Bleu-1
BiDAF [15]	16.91	9.30	23.96	10.64
Deep Cascade QA [24]	35.14	37.35	52.01	<b>54.64</b>
S-Net [20]	45.04	40.62	44.96	46.36
VNET [22]	48.37	46.75	51.63	54.37
Masque (Q&A; single)	25.66	36.62	50.93	42.37
Masque (NLG; single)	49.19	49.63	48.42	48.68
Masque (Q&A; ensemble)	28.53	39.87	<b>52.20</b>	43.77
Masque (NLG; ensemble)	<b>49.61</b>	<b>50.13</b>	48.92	48.75
Human Performance	63.21	53.03	53.87	48.50

表 2: MS MARCO 2.1 のリーダーボードにおける評価結果 (2019/01/03 付. 主指標: Rouge-L). 比較モデルの単一・アンサンブルの区別は非公開.

Model	Rouge-L	Bleu-1
Masque (NLG style; single) <sup>1</sup>	<b>69.77</b>	<b>65.56</b>
w/o multi-style learning (§3.4.2) <sup>2</sup>	68.20	63.95
↪ w/o Transformer (§3.1.2, §3.4.2) <sup>2</sup>	67.13	62.96
w/o passage ranker (§3.2) <sup>2</sup>	68.05	63.82
w/o possibility classifier (§3.3) <sup>3</sup>	69.64	65.41
Masque <sup>1</sup> w/ gold passage ranker	78.70	78.14

表 3: Ablation テスト結果 (NLG タスク, WFA dev).

<sup>1</sup>ALL, <sup>2</sup>WFA, <sup>3</sup>ANS セットにて学習.

用い,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ ,  $\epsilon = 10^{-8}$  とした. モデルパラメータは  $N(0, 0.02)$  で初期化した. 最初の 2000 ステップで学習率を 0 から  $2.5 \times 10^{-4}$  に線形的に増加させ, その後 cosine スケジュールにより 0 に近づけた. 勾配は最大ノルム 1 でクリッピングした. L<sub>2</sub> 正則化 [7] を実施した. highway network および multi-head アテンションに対してドロップアウト率 0.3 を設定した. ランカー, 分類器に対して正例の重みを 0.9 として one-sided label smoothing [18] を行った.

### 4.2 機械読解精度に関する評価

モデル全体の回答精度および各貢献について評価した.

提案モデルは生成型読解において **state-of-the-art** の性能を達成するか? 表 2 に示す様に, 提案モデルのアンサンブルは両タスクにおいて Rouge-L の指標で抽出型モデル [15, 24, 22] を上回る state-of-the-art の性能を達成した. 特に, NLG タスクにおいては単一のモデルにて比較モデルの性能を大きく上回った. Q&A スタイルでは簡潔な回答を試みるため, NLG スタイルに比べて正解時の Rouge-L は高いが, 不正解時の Bleu-1 は極端に低くなる傾向があった.

複数スタイルの同時学習は読解の性能向上に寄与するか? 表 3 に示す様に, 2 スタイルを 1 モデルで学習し回答スタイルに NLG を指定したモデルは, NLG スタイルのみで学習したモデルの性能を上回った.

Transformer ベースの **pointer-generator** は読解の性能向上に寄与するか? 表 3 に示す様に, Transformer を用いる提案モデルは, LSTM および self-attention を用いる構成 ([8] と同様) を上回った.

Model	MAP	MRR
Bing (initial ranking)	34.62	35.00
Masque (single) <sup>1</sup>	<b>69.51</b>	<b>69.96</b>
w/o answer decoder (§3.4) <sup>1</sup>	67.03	67.49
w/o multi-style learning (§3.4.2) <sup>2</sup>	65.51	65.59
w/o possibility classifier (§3.3) <sup>3</sup>	69.08	69.54

表 4: パッセージランキングの評価結果 (ANS dev).

<sup>1</sup>ALL, <sup>2</sup>WFA, <sup>3</sup>ANS セットにて学習.

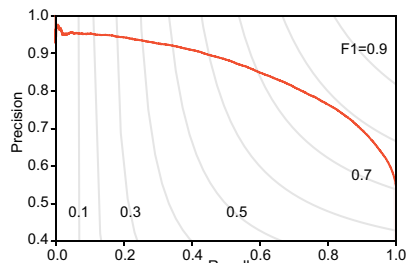


図 3: 回答可否分類の Precision-Recall (ALL dev).

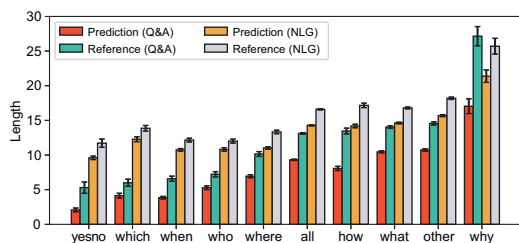


図 4: スタイル・クエリタイプ別の正解・出力の回答文長 (WFA dev). エラーバーは標準誤差を表す.

ランカーおよび分類器との同時学習は読解の性能向上に寄与するか? 表 3 に示す様に, 提案モデルは, ランカーおよび分類器を用いない構成を上回った. また, ランカーが常に正しい出力をすると仮定 (gold 条件) した場合, 著しい性能向上が確認できた. 無関係なパッセージの除去がさらなる精度向上のために重要である.

### 4.3 その他の分析

パッセージランキング, 回答可否分類の精度に関して評価する. さらに, 回答文長および生成例を分析する.

マルチタスク学習はパッセージランキングの性能向上にも寄与するか? 表 4 に評価結果を示す. まず, 提案モデルのランカーは, Bing の初期ランキングの性能を大きく改善した. 最大の要因は, 複数スタイルの同時学習により学習データ数が増加したことであった. また, 回答文デコーダを取り除きランカー単体の評価を行ったところ, [9] の報告と同様に性能が悪化した.

回答可能な質問を高精度に識別できるか? 図 3 に示す通り, 出力  $P(a)$  に閾値を設定することで高い識別率 ( $F_1$  最大: 0.7893) を実現できた.

回答文長の分析. 図 4 に示す通り, 提案モデルは指定したスタイルに応じて適切に回答を制御出来ていた. また, when・who など factoid 型の質問には短く, why など non-factoid 型の質問には長く回答出来ていた.

生成例・エラー分析. 表 5 にスタイル毎の生成例を示す. NLG では質問・パッセージの要約となる自然な文章を出力できた. 主なエラーとしては, Yes/No 回答の誤り, 数値のコピーの誤りが挙げられる.

**Question:** why your body would feel like it is shaking

**Relevant Passage:** (...) Shaking can be due to cold body temperatures, rising fever (such as with infections), neurological problems, medicine effects, drug abuse, etc. (...)

**Reference Answer (Q&A):** Shaking can be due to cold body temperatures, rising fever (such as with infections), neurological problems, medicine effects, drug abuse, etc.

**Prediction (Q&A):** because of cold body temperatures, rising fever, neurological problems, medicine effects, drug abuse.

**Reference Answer (NLG):** Body would feel like it is shaking due to cold body temperatures, rising fever, neurological problems, medicine effects, drug abuse.

**Prediction (NLG):** your body would feel like it is shaking because of cold body temperatures, rising fever, neurological problems, medicine effects, drug abuse.

表 5: 提案モデルによるスタイル別生成例. 赤: コピー (パッセージ), 緑: コピー (質問), 橙: 語彙生成.

## 5 おわりに

本研究では回答スタイルを制御可能な生成型の機械読解モデル Masque を提案し, MS MARCO 2.1 の 2 タスクにて state-of-the-art の性能を達成した.

**関連研究と議論.** 従来の生成モデル MCAN [8] は pointer-generator を用いて複数の NLP タスクを同時学習したが, 機械読解の精度は向上しなかった. また, パッセージが複数個与えられる場合を考慮していない. S-Net [20] はパッセージから範囲を抽出し, 抽出範囲に基づいて回答を生成する. しかし, 質問やパッセージからのコピーを実施できない. また, これらは複数の回答スタイルを考慮していない. 本研究では, 複数スタイルの同時学習および質問・複数パッセージからコピー可能な pointer-generator を導入することで著しい精度向上を実現した. また, Transformer への拡張, ランカー・分類器とのマルチタスク学習も貢献した.

**本研究の重要性.** 機械読解における回答スタイルに初めて着目し, 汎用性の高いトークン挿入方式にて, 複数スタイルの同時学習の有効性を示した. 提案モデルは, スマートデバイスやチャットボットにおける自然言語での質問応答, 少リソースの回答スタイル (キャラクター性など) に基づく質問応答など, 産業上重要な課題に対して応用可能である.

## 参考文献

- [1] L. J. Ba et al., *arXiv*, 1607.06450, 2016.
- [2] P. Bajaj et al., *arXiv*, 1611.09268v3, 2018.
- [3] J. Devlin et al., *arXiv*, 1810.04805, 2018.
- [4] D. Hendrycks et al. *arXiv*, 1606.08415, 2016.
- [5] H. Inan et al., In *ICLR*, 2017.
- [6] M. Johnson et al., *TACL*, 5:339–351, 2017.
- [7] I. Loshchilov et al., *arXiv*, 1711.05101, 2017.
- [8] B. McCann et al., *arXiv*, 1806.08730, 2018.
- [9] K. Nishida et al., In *CIKM*, pages 647–656, 2018.
- [10] J. Pennington et al., In *EMNLP*, pages 1532–1543, 2014.
- [11] M. E. Peters et al., In *NAACL*, pages 2227–2237, 2018.
- [12] P. Rajpurkar et al., In *EMNLP*, pages 2383–2392, 2016.
- [13] P. Rajpurkar et al., In *ACL*, pages 784–789, 2018.
- [14] A. See et al., In *ACL*, pages 1073–1083, 2017.
- [15] M. Seo et al., In *ICLR*, 2017.
- [16] R. K. Srivastava et al., *arXiv*, 1505.00387, 2015.
- [17] M. Sun et al., In *ACL*, pages 132–141, 2018.
- [18] C. Szegedy et al., In *CVPR*, pages 2818–2826, 2016.
- [19] S. Takeno et al., In *WAT@IJCNLP*, pages 55–63, 2017.
- [20] C. Tan et al., In *AAAI*, pages 5940–5947, 2018.
- [21] A. Vaswani et al., In *NIPS*, pages 6000–6010, 2017.
- [22] H. Wu et al., In *ACL*, pages 1918–1927, 2018.
- [23] C. Xiong et al., In *ICLR*, 2017.
- [24] M. Yan et al., *arXiv*, 1811.11374, 2018.