

# Data-to-Text における主題遷移のモデル化

磯 颯 ♠♠ 上原 由衣 ♣ 石垣 達也 ♠♠ 能地 宏 ♣ 荒牧 英治 ♠♠  
 小林 一郎 ♠♠ 宮尾 祐介 ♠♠ 岡崎 直観 ♠♠ 高村 大也 ♠♠

♠ 奈良先端科学技術大学院大学 ♣ 産業技術総合研究所  
 ♠ 東京工業大学 ♠ お茶の水女子大学 ♠ 東京大学

{iso.hayate.id3, aramaki}@is.naist.jp {yui.uehara, noji}@aist.go.jp  
 ishigaki@lr.pi.titech.ac.jp koba@is.ocha.ac.jp

yusuke@is.s.u-tokyo.ac.jp okazaki@c.titech.ac.jp takamura@pi.titech.ac.jp

## 1 はじめに

センサ技術やデータ保管技術の発展により、気象、金融、スポーツなど様々な分野においてデータが増加しつつある。これらを有効利用するための一つの手段として、データの内容を自然言語の文章で表現し、人間にとって解釈しやすくする data-to-text 生成技術がある。近年のニューラルテキスト生成技術の発展に伴い、特に少数の入力から短い文を生成する data-to-text タスクにおいて、質の高い文が生成できるようになってきた [6]。しかし、情報の取捨選択が必要なデータから長い文書を生成した場合、入力データと矛盾していたり、重要度の低い情報に関する文が生成されてしまう問題がある [11]。例えば、バスケットボールの試合についてのボックススコア (表 1(a)) からの試合の要約文書 (表 1(b)) の生成という研究課題において、選手 A に言及しているにも関わらず選手 B の得点数を生成してしまう、あるいは本来言及すべき選手 C ではなく、あまり活躍していない選手 D に関する文を生成してしまう場合がある。

本研究では、テキストの生成過程で、主題の遷移を同時に捉えることのできるモデルを用いて、これらの問題に対処する。表 2 に示すように、提案モデルは、各時刻において主題となるエンティティ (e.g., HAWKS) や、そのエンティティの属性 (e.g., PTS (得点数)) を特定し、それらによって条件付けられた文書生成を行う。これにより、過去の主題の遷移から尤もらしいエンティティやその属性を参照することができる。また、各試合において重要なエンティティを参照するため、ボックススコアからエンティティを特徴づけ、重要度の高いエンティティを優先的に選択させるようにモデルの学習を行った。実験の結果、提案モデルは文書の質を保持しつつ、先行研究と比較し、より入力データと矛盾せず、重要な情報を含んだ試合の要約文書を生成することに成功した。

## 2 関連研究

Data-to-text 生成課題は、構造化データや数値データなど様々な種類の入力データに対し、それを説明す

TEAM	WIN	LOSS	PTS	FG_PCT	REB	AST	...
HAWKS	11	12	103	49	47	27	...
HEAT	7	15	95	43	33	20	...

PLAYER	H/V	AST	REB	PTS	FGM	CITY	...
DWIGHT HOWARD	H	4	17	23	9	ATLANTA	...
DENNIS SCHRODER	H	7	4	17	8	ATLANTA	...
HASSAN WHITESIDE	V	0	12	8	4	MIAMI	...
TYLER JOHNSON	V	5	2	27	7	MIAMI	...
...	...	...	...	...	...	...	...

(a) ボックススコア：上の表は各チームの統計値であり、その試合までの勝敗数や、その試合での得点数などの統計値から成る。下の表は選手ごとの統計値であり、その試合での得点数やアシスト数などから成る。

The Atlanta Hawks defeated the Miami Heat , 103 - 95 , at Philips Arena on Wednesday . Atlanta was in desperate need of a win and they were able to take care of a shorthanded Miami team here . . . Tyler Johnson was the team ' s best player , as he tallied 27 points and five assists off the bench . . .

(b) 試合の要約文書：試合の勝敗や、活躍した選手などの紹介などを含む。

表 1: データ例：ボックススコア (a) が入力となり、試合の要約文書 (b) を出力する。

るテキストを生成する研究課題である。これまで、スポーツ実況 [10] や天気予報 [5]、株価の概況テキスト生成 [1, 7]、人物紹介テキスト生成 [6] など、多くのドメインで研究が進められてきた。ニューラルネットワークの発展により、テキスト生成技術も大きく発展したものの、これまで研究対象となったのは、ヘッドラインなど短い文の生成であることが多かった。

近年、より長い文章の生成も注目されつつある。RO-TOWIRE データ [11] は、表 1 に示すようにバスケットボールの試合のボックススコアと、試合の要約文書の対からなるデータであり、生成対象である試合の要約文書は複数の文からなる。また、入力情報も多く、言及すべき重要な情報を選択し、それを正確に記述することが必要となる。こうしたデータに対し、既存のニューラルテキスト生成モデルを適用した場合、異なる入力情報を参照してしまい、結果として事実とは異なる文

$t$	1	2	3	4	5	6	7	8	9	10	11	...	197	198	199	200	201	202	203
$Y_t$	The Atlanta Hawks defeated the Miami Heat , 103 - 95 ... he tailed 27 points and five assists																		
$Z_t$	0	1	1	0	0	1	1	0	1	0	1	...	0	0	1	0	0	1	0
$E_t$	-	HAWKS	HAWKS	-	-	HEAT	HEAT	-	HAWKS	-	HEAT	...	-	-	TYLER JOHNSON	-	-	TYLER JOHNSON	-
$A_t$	-	CITY	TEAM	-	-	CITY	TEAM	-	PTS	-	PTS	...	-	-	PLAYER PTS	-	-	PLAYER AST	-
$N_t$	-	-	-	-	-	-	-	-	1	-	1	...	-	-	1	-	-	0	-

表 2: 提案モデルの生成例. 各時刻  $t$  における各確率変数の値と生成された単語を示す. 例えば  $t = 11$  では, 入力を参照すべきと判定し ( $Z_{11} = 1$ ), 参照すべきエンティティとして HEAT を選択し ( $E_{11} = \text{HEAT}$ ), 参照すべき属性として PTS(得点数) を選択し ( $A_{11} = \text{PTS}$ ), その結果, 入力データから HEAT の得点数 95 をコピーして出力している.

を生成してしまうことが知られている.

本研究と最も関連が強い研究 [9] では, 入力データから生成に用いる関係系列を出力し, その関係系列を文書生成の入力として用いることで, 事実関係を明示的に扱っている. しかし同研究は, デコードの各時点において参照すべき入力を, 関係系列から自動的に獲得する必要があり, 入力データの間接関係を正しく文として生成することは難しい.

一方, エンティティの状態を追跡しながら言語モデリング [4] や物語生成 [2] を行うことで, 一貫性の高いテキストの生成が可能となっている. これらの研究では, 事前に学習された共参照解析器を用いて, テキストにアノテーションを行い, 学習を行っている. 本研究はこれらの研究を発展させ, 主題やその転換を追跡モデルを用いて保持しながら文書の生成を行うことで, 長文を対象とした data-to-text 生成課題において, 一貫性の高い文書の生成を可能とした.

### 3 選択的追跡モデルによる文書生成

本研究で扱うデータは, 選手などのエンティティ  $e$ , 得点数などの属性  $a$ , その属性値  $v$  からなるタプル  $r = (e, a, v)$  の集合とみなすことができる. 例えば, 表 1 から (TYLER JOHNSON, PTS, 27) というタプルを得ることができる. 入力となるボックススコアを  $\mathbf{x}$  で表し,  $\mathbf{x}$  におけるエンティティ  $e$  の属性  $a$  の属性値を,  $\mathbf{x}[e, a]$  で表す. また, エンティティの集合を  $\mathcal{E}$ , 属性の集合を  $\mathcal{A}$  で表す.

提案モデルは, データ  $\mathbf{x}$  を入力とし, 言語モデルの隠れ状態  $\mathbf{h}^{\text{LM}}$  と, 追跡モデルの隠れ状態  $\mathbf{h}^{\text{ENT}}$  から, 文書  $y_{1:T} = (y_1, \dots, y_T)$  の生成を行う. 言語モデルの隠れ状態  $\mathbf{h}^{\text{LM}}$  が, 直前に生成された単語  $y_t$  と文脈ベクトルを用いて更新されるのに対し, 追跡モデルの隠れ状態  $\mathbf{h}^{\text{ENT}}$  は, 新たに導入する 4 つの確率変数の実現値によって, 更新方式が決定される.

1. 確率変数  $Z_t$ : 時刻  $t$  において, 入力  $\mathbf{x}$  を参照する ( $Z_t = 1$ ) か否か ( $Z_t = 0$ ) を判定する二値変数
2. 確率変数  $E_t$ : 時刻  $t$  において, 主題となるエンティティ (e.g., HAWKS) を示す変数
3. 確率変数  $A_t$ : 時刻  $t$  において主題となるエンティティ  $E_t$  に対し, 言及する属性を示す変数 (e.g., PTS)
4. 確率変数  $N_t$ : 時刻  $t$  において言及されるエンティティ

ティ  $e$  の属性  $a$  が数値属性である場合に, 該当する属性値 (e.g., 50) を, アラビア数字で出力する ( $N_t = 1$ ) か, 数詞で生成する ( $N_t = 0$ ) かを判定する二値変数

上記の確率変数を文書の生成過程で予測しながら, 追跡モデルの状態を更新し, それを生成に利用することで, 各時点における主題を考慮しながら文書の生成を行う. 以下の節では, これらの確率変数の実現値をどのように推定していくか説明する. 紙面の関係上, バイアスペクトルは省略して記述する.

#### 3.1 モデルの初期化

エンティティ  $e$ , 属性  $a$ , 属性値  $v$  の埋め込み表現  $\mathbf{e}$ ,  $\mathbf{a}$ ,  $\mathbf{v}$  がそれぞれ与えられているとき, タプル  $(e, a, v)$  の埋め込み表現を  $\mathbf{r}_{e,a,v}$  を以下のように定義する:

$$\mathbf{r}_{e,a,v} = \tanh(\mathbf{W}_r(\mathbf{e} \oplus \mathbf{a} \oplus \mathbf{v})). \quad (1)$$

ここで,  $\oplus$  はベクトルの連結を表す. このとき, 入力データ  $\mathbf{x}$  における, エンティティ  $e$  の埋め込み表現  $\bar{\mathbf{e}}$  を次のように定義する:

$$\bar{\mathbf{e}} = \tanh\left(\sum_{a' \in \mathcal{A}} \mathbf{W}_{a'} \mathbf{r}_{e,a',\mathbf{x}[e,a']}\right). \quad (2)$$

$\mathbf{e}$  はすべての試合で共通して決められる埋め込み表現であるのに対し,  $\bar{\mathbf{e}}$  は対象としている試合の情報を入れた, その試合における対象エンティティの埋め込み表現であることを強調しておく.

#### 3.2 入力データの参照

各時刻  $t$  において, 新たに入力を参照するか決める:

$$p(Z_t = 1 | \mathbf{h}_{t-1}^{\text{LM}}, \mathbf{h}_{t-1}^{\text{ENT}}) = \sigma(\mathbf{W}_z(\mathbf{h}_{t-1}^{\text{LM}} \oplus \mathbf{h}_{t-1}^{\text{ENT}})).$$

ここで,  $\sigma(\cdot)$  をシグモイド関数とする.

入力データを新たに参照する場合 ( $Z_t = 1$ ) には, 主題となるエンティティとその属性を推定 (3.3-3.4 節) し, その後単語の生成を行う (3.6 節).

一方, 主題が変わらない場合 ( $Z_t = 0$ ) には, 追跡モデルを更新せずに, 次の単語の生成を行う (3.6 節).

#### 3.3 主題となるエンティティ

各時刻  $t$  において, 入力データを参照する場合 ( $Z_t = 1$ ), どのエンティティが主題となるか決定する. 時刻  $t$  において既に参照されているエンティティの集合を  $\mathcal{E}_{t-1}$  としたとき, 参照するエンティティの確率を以下

のように計算する：

$$p(E_t = e | \mathbf{h}_{t-1}^{\text{LM}}, \mathbf{h}_{t-1}^{\text{ENT}}) \propto \begin{cases} \exp\left(\mathbf{h}_s^{\text{ENT}} \mathbf{W}_{\text{obs}} \mathbf{h}_{t-1}^{\text{LM}}\right) & \text{if } e \in \mathcal{E}_{t-1} \\ \exp\left(\bar{\mathbf{e}} \mathbf{W}_{\text{new}} \mathbf{h}_{t-1}^{\text{LM}}\right) & \text{otherwise} \end{cases}.$$

ここで、 $s = \max\{s : s \leq t-1, e = e_s\}$  と定義する。 $s$  は、時刻  $t-1$  から見て、既に観測されているエンティティ  $e$  が参照された最も新しい時刻を表す。

追跡モデルの隠れ状態  $\mathbf{h}^{\text{ENT}}$  は次のように更新する。主題として選ばれたエンティティ  $e$  が、新たに参照されたエンティティ ( $e \notin \mathcal{E}_{t-1}$ ) であった場合、エンティティの埋め込み表現  $\bar{\mathbf{e}}$  を入力とし、隠れ状態  $\mathbf{h}^{\text{ENT}}$  を更新する：

$$\mathbf{h}_{t-1}^{\text{ENT}'} = \text{GRU}_E(\bar{\mathbf{e}}, \mathbf{h}_{t-1}^{\text{ENT}}).$$

一方、エンティティ  $e$  に過去に言及しており ( $e \in \mathcal{E}_{t-1}$ )、かつ直前の時刻に主題であったエンティティと異なる場合、 $e$  に関する最新の隠れ状態  $\mathbf{h}_s^{\text{ENT}}$  を入力として、現時刻の隠れ状態を  $\mathbf{h}^{\text{ENT}}$  更新する：

$$\mathbf{h}_{t-1}^{\text{ENT}'} = \text{GRU}_E(\mathbf{W}_s \mathbf{h}_s^{\text{ENT}}, \mathbf{h}_{t-1}^{\text{ENT}}).$$

直前の時刻に主題であったエンティティと同一である場合、 $\mathbf{h}_{t-1}^{\text{ENT}}$  の更新は行わない ( $\mathbf{h}_{t-1}^{\text{ENT}'} = \mathbf{h}_{t-1}^{\text{ENT}}$ )。

### 3.4 主題となるエンティティの属性

時刻  $t$  においてエンティティ  $e_t$  が主題であるとし、どの属性に対して言及するかを以下の確率で決定する：

$$p(A_t = a | e, \mathbf{h}_{t-1}^{\text{LM}}, \mathbf{h}_{t-1}^{\text{ENT}'}) \propto \exp\left(\mathbf{r}_{e,a,\mathbf{x}[e,a]} \mathbf{W}_a (\mathbf{h}_{t-1}^{\text{LM}} \oplus \mathbf{h}_{t-1}^{\text{ENT}'})\right).$$

ここで、選択されたエンティティ  $e$ 、選択された属性  $a$ 、および対応する入力データ  $\mathbf{x}[e,a]$  から成るタブルの埋め込み表現  $\mathbf{r}_{e,a,\mathbf{x}[e,a]}$  を用いて、次の時刻  $t$  での追跡モデルの隠れ状態  $\mathbf{h}^{\text{ENT}}$  を計算する：

$$\mathbf{h}_t^{\text{ENT}} = \text{GRU}_A(\mathbf{r}_{e,a,\mathbf{x}[e,a]}, \mathbf{h}_{t-1}^{\text{ENT}'}) .$$

このとき、主題の転換の際に用いられた  $\text{GRU}_E$  と異なる  $\text{GRU}_A$  を用いて隠れ状態を計算する。

### 3.5 数値データの形式判定

エンティティ  $e$  に対し、選択された属性  $a$  が数値属性である場合、入力の該当部分である  $\mathbf{x}[e,a]$  を出力する。ここでは、確率変数  $N_t$  を用いて、その数値をアラビア数字として出力する ( $N_t = 1$ ) か、数詞として出力する ( $N_t = 0$ ) かを、以下の確率で決定する：

$$p(N_t = 1 | \mathbf{h}_{t-1}^{\text{LM}}, \mathbf{h}_t^{\text{ENT}}) = \sigma(\mathbf{W}_n (\mathbf{h}_{t-1}^{\text{LM}} \oplus \mathbf{h}_t^{\text{ENT}})).$$

このとき、文脈ベクトルによる単語  $y_t$  の予測は行わない。

## 3.6 文書の生成

時刻  $t$  における、追跡モデルの隠れ状態が更新されたとき、文脈ベクトル  $\mathbf{h}'_t$  を構成する：

$$\mathbf{h}'_t = \tanh\left(\mathbf{W}_h (\mathbf{h}_{t-1}^{\text{LM}} \oplus \mathbf{h}_t^{\text{ENT}})\right).$$

時刻  $t$  における文脈ベクトル  $\mathbf{h}'_t$  から、Class Factored Softmax [3] を用い、単語の生成確率を計算する：

$$p(Y_t | \mathbf{h}'_t) = \text{CFSM}(\mathbf{W}_y \mathbf{h}'_t).$$

得られた単語確率から最も高い確率を持つ単語を時点  $t$  の生成単語  $y_t$  として出力し、その埋め込み表現  $\mathbf{y}_t$  を用いて言語モデルを更新する ( $\mathbf{h}_t^{\text{LM}} = \text{LSTM}(\mathbf{y}_t \oplus \mathbf{h}'_t, \mathbf{h}_{t-1}^{\text{LM}})$ )。

## 4 実験

### 4.1 実験設定

#### 4.1.1 評価指標

先行研究 [11] に従い、BLEU-4 スコアと、Relation Generation (RG), Content Selection (CS), Content Ordering (CO) を評価指標として用いる。これらは生成結果  $\hat{y}_{1:T}$  と真の文書  $y_{1:T}$  から、関係タブル抽出モデル\*1により得られたタブルから、次のように定義する。

- Relation Generation (RG): 生成結果  $\hat{y}_{1:T}$  から抽出されたタブルのうち、入力  $\mathbf{x}$  の情報に含まれているものの割合すなわち適合率であり、入力のタブルを正しく生成できているかを測る指標。
- Content Selection (CS): 真の文書  $y_{1:T}$  から抽出されたタブルを正解集合としたときの、生成結果  $\hat{y}_{1:T}$  から抽出されるタブルの適合率、再現率、F 値。真の文書で言及されたタブルが、生成文書でも同様に言及されているかを測る指標。
- Content Ordering (CO): 生成結果  $\hat{y}_{1:T}$  と、真の文書  $y_{1:T}$  から抽出されたタブルの normalized Damerau-Levenshtein Distance (DLD)。正しい順序で入力のタブルを生成しているかを測る指標。

#### 4.1.2 実験データ

ROTOWIRE データ [11] を用いて、モデルの学習と評価を行う。ROTOWIRE データは、NBA の各試合結果の要約文書とそのボックススコアで構成されている。試合結果の要約文書は平均 337 単語と、文書生成タスクの中でも比較的長い文書の生成を必要とするデータである [5]。入力データ  $\mathbf{x}$  のうち、各選手に関する属性の種類は 24 個、各チームに関する属性の種類は 15 個

\*1 関係タブル抽出モデルは、テキストからエンティティ (e.g., チーム名, 都市名, 選手名) と、属性値 (e.g., “Heat”, “95”) を抽出し、そのペアに対応する属性 (e.g., “TEAM NAME”, “PTS”) を、ボックススコアから特定することで作ったタブルを用いて学習する。本研究で用いる関係タブル抽出モデルは、テストデータにおいて 94% の適合率、80% の再現率でタブル抽出を行うことができる [9]。

手法	RG		CS			CO	BLEU-4
	#	P%	P%	R%	F1%	DLD%	
GOLD	24.14	94.90	100.	100.	100.	100.	100.
WSR'17	23.72	74.80	29.49	36.18	32.49	15.42	14.19
Nie+'18	-	-	-	-	-	-	14.74
PDL'19	34.28	87.47	34.18	<b>51.22</b>	40.99	18.52	<b>16.50</b>
提案手法	23.02	<b>91.55</b>	<b>42.24</b>	42.06	<b>42.16</b>	<b>21.70</b>	14.95

表 3: 実験結果. 各手法が, 入力データから重要な情報 (CS) を正確 (RG) かつ正しい順序 (CO) で記述することができるかを評価している.

あり, 各試合について平均 628 個の属性値が入力として用いられる. 学習データ, 開発データ, テストデータの事例数はそれぞれ 3,398, 727, 728 である.

#### 4.1.3 モデル

提案モデルの評価のため, 比較手法を以下のように設定する.

- WSR'17 [11]: 注意機構, コピー機構を備えた encoder-decoder モデル.
- Nie+'18 [8]: WSR'17 に加え, 事前に定義した操作 (e.g., arg max) によって得られたデータを追加の入力として用いたモデル.
- PDL'19 [9]: 入力データ  $x$  から, 生成に用いるタプル系列を予測し, それを用いて文書生成を行うモデル.

また, 提案モデルの埋め込み表現の次元を 128, LSTM, GRU の隠れ状態の次元を 512 に設定し, 100 エポック学習し, 開発データの BLEU-4 値が最大となるモデルを評価に用いる. 学習率の自動調整には AMSGrad を用いる.

#### 4.2 実験結果

表 3 に実験結果を示す. 提案モデルは, RG の適合率, CS の適合率, F 値, CO の DLD において最も高い値を示した.

一方, PDL'19 が, CS の再現率, BLEU-4 スコアにおいて最も高い値を示している. PDL'19 は, 生成したタプルの数 (# of RG) が他のモデルよりも多いため, CS の再現率が高くなっていると考えられる. しかし, その副作用として CS の適合率が低くなっており, F 値で見ると, 提案モデルが最も正確に内容選択できていると言える.

#### 4.3 議論

実験の結果, 関係タプル抽出に関する評価指標 (RG, CS, CO) において, 提案モデルは高い値を示したが, BLEU-4 スコアに関しては, PDL'19 [9] と比較し, 約 1.5 ポイント低い結果となった. しかし, Nie+'18 [8] の調査によると, 真の文書  $y_{1:T}$  に含まれる事実関係のうち, 27.1% はデータから推測できないと言われていた. また, 各文書に關係抽出モデルを適用したところ, 文単位で見ると 49.0% の文からはタプル (e.g., (HEAT, PTS, 95)) を抽出することができないことが明らかと

なった. 即ち, BLEU-4 による生成文書の評価には, 入力データとは関係のない文が影響し, 適切な評価ができていない可能性がある.

一方, 関係タプル抽出を必要とする評価指標 (RG, CS, CO) は, 全て入力データから類推できる事実を正しく生成できているかを評価する指標である. 提案モデルは CS の再現率を除いた全ての指標で最も高い値を示しており, より入力データから有用な情報を矛盾なくテキストとして生成できたとと言える.

## 5 おわりに

本研究では, 主題の遷移を追跡しながら文書の生成を行う data-to-text モデルを提案した. 実験の結果, 提案モデルの生成結果は, 先行研究と比較し, 入力データの有用な情報をより正確に生成することに成功した.

今後の展望として, 本研究でアノテーション対象外となっている文を分析し, その文を再現することのできる関係を新たにアノテーションすることで, 本研究では考慮できていない部分も含めた生成文の向上を目指す.

謝辞 この成果は, 国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務, JST さきがけ JPMJPR1655, および産総研-東工大 OIL の支援の結果得られたものです.

## 参考文献

- [1] Tatsuya Aoki, Akira Miyazawa, Tatsuya Ishigaki, Keiichi Goshima, Kasumi Aoki, Ichiro Kobayashi, Hiroya Takamura, and Yusuke Miyao. Generating market comments referring to external resources. In *INLG*, pp. 135–139, 2018.
- [2] Elizabeth Clark, Yangfeng Ji, and Noah A Smith. Neural text generation in stories using entity representations as context. In *NAACL-HLT*, pp. 2250–2260, 2018.
- [3] Joshua Goodman. Classes for fast maximum entropy training. In *ICASSP*, pp. 561–564. IEEE, 2001.
- [4] Yangfeng Ji, Chenhao Tan, Sebastian Martschat, Yejin Choi, and Noah A Smith. Dynamic entity representations in neural language models. In *EMNLP*, pp. 1830–1839, 2017.
- [5] Percy Liang, Michael I Jordan, and Dan Klein. Learning semantic correspondences with less supervision. In *ACL-IJCNLP*, pp. 91–99, 2009.
- [6] Tianyu Liu, Kexiang Wang, Lei Sha, Baobao Chang, and Zhifang Sui. Table-to-text generation by structure-aware seq2seq learning. In *AAAI*, 2018.
- [7] Soichiro Murakami, Akihiko Watanabe, Akira Miyazawa, Keiichi Goshima, Toshihiko Yanase, Hiroya Takamura, and Yusuke Miyao. Learning to generate market comments from stock prices. In *ACL*, pp. 1374–1384, 2017.
- [8] Feng Nie, Jinpeng Wang, Jin-Ge Yao, Rong Pan, and Chin-Yew Lin. Operation-guided neural networks for high fidelity data-to-text generation. In *EMNLP*, pp. 3879–3889, 2018.
- [9] Ratish Puduppully, Li Dong, and Mirella Lapata. Data-to-text generation with content selection and planning. In *AAAI*, 2019.
- [10] Kumiko Tanaka-Ishii, Kôiti Hasida, and Itsuki Noda. Reactive content selection in the generation of real-time soccer commentary. In *COLING-ACL*, pp. 1282–1288, 1998.
- [11] Sam Wiseman, Stuart Shieber, and Alexander Rush. Challenges in data-to-document generation. In *EMNLP*, pp. 2253–2263, 2017.