



Title	ユーザの意思決定における有用なテキスト情報の生成に関する研究
Author(s)	吉田, 拓海
Citation	北海道大学. 博士(情報科学) 甲第16002号
Issue Date	2024-03-25
DOI	10.14943/doctoral.k16002
Doc URL	http://hdl.handle.net/2115/91930
Type	theses (doctoral)
File Information	Takumi_Yoshida.pdf



[Instructions for use](#)

ユーザの意思決定における
有用なテキスト情報の生成に関する研究

吉田 拓海

北海道大学 大学院情報科学院

2024年1月

目次

1 序論	1
1.1 研究背景	1
1.2 研究目的	2
1.3 本論文の構成	3
2 関連研究	4
2.1 意思決定に関する研究分野	4
2.1.1 意思決定問題について	4
2.1.2 人間の意思決定の過程	5
2.1.3 自動意思決定と意思決定支援	6
2.2 有用なテキスト情報の生成	6
2.2.1 テキスト情報の元となるデータの生成	7
2.2.2 テキスト情報の生成	8
2.2.3 個人化された情報の生成	9
3 機械学習によるレース展開の予測	11
3.1 はじめに	11
3.2 予測器の入力・出力の検討	12
3.2.1 提案手法	12
3.2.2 2人モデル・9人モデルの比較	16
3.2.3 1人モデル・2人モデル・9人モデルの比較	19
3.3 レース展開の予測	27
3.3.1 問題設定	27
3.3.2 提案手法	27
3.3.3 予測精度の検証	29
3.4 まとめ	34

4	テキスト情報の生成	36
4.1	はじめに	36
4.2	テンプレートを用いた生成手法の検討	37
4.2.1	競輪におけるテキスト情報	38
4.2.2	テキスト情報の生成手法	39
4.2.3	テキスト情報の生成結果・考察	41
4.3	テンプレートを用いた生成手法によるテキスト情報の生成と評価	42
4.3.1	競輪におけるテキスト情報	43
4.3.2	生成手法	48
4.3.3	生成したテキスト情報の評価実験	50
4.4	ニューラル言語モデル (GPT-2) による生成手法の性能の検証	54
4.4.1	実験設定	54
4.4.2	結果・考察	56
4.5	まとめ	58
5	個人化された情報の有効性の検証	60
5.1	はじめに	60
5.2	競輪における代表的なユーザタイプ	60
5.2.1	スポーツ競技	60
5.2.2	公営競技	61
5.2.3	ユーザの行動・情報・行動	61
5.3	テキスト情報の生成手法	62
5.3.1	テキスト情報の生成に使用したデータ	62
5.3.2	テキスト情報の生成に使用したテンプレート	63
5.4	生成したテキスト情報の評価実験	64
5.4.1	実験設定	64
5.4.2	結果・考察	65
5.5	まとめ	65
6	結論	69
	参考文献	73

図目次

1.1	本論文の構成の概略図	3
3.1	予測モデルの比較 (三連単的中確率の推定精度)	25
3.2	Transformer による予測器の概略図	28
3.3	MLP による予測器の概略図	32
4.1	テンプレートを用いたテキスト情報の生成の概要	37
4.2	記事内での言及選手数の頻度分布	47
4.3	評価者全体の評価値の頻度分布	55
5.1	各設問における評価値の頻度分布. レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か? (“Is the information valuable to predicting-oriented users?”) とレースを観戦し楽しむことを重視するユーザにとって価値のある情報か? (“Is the information valuable to viewing-oriented users?”) について.	66

表目次

3.1	入力特徴量	17
3.2	ハイパーパラメータの探索範囲	18
3.3	2人モデルのハイパーパラメータ	18
3.4	9人モデルのハイパーパラメータ	19
3.5	結果	20
3.6	入力特徴量	22
3.7	予測モデルの比較 (1着, 二車単, 三連単の Top K accuracy)	23
3.8	予測モデルの比較 (三連単の中確率の推定誤差)	25
3.9	予測モデルの比較 (回収率)	26
3.10	特徴量	30
3.11	ハイパーパラメータの探索範囲	33
3.12	二車単 y_1, y_2 , 三連単 y_1, y_2, y_3 , 展開を含んだ二車単 y_0, y_1, y_2 の Top-K Accuracy	33
3.13	1レースの予測にかかる時間 [秒] (100 試行)	34
3.14	Transformer による予測器の回収率	34
4.1	生成したテキスト情報と既存のテキスト情報の例 1	42
4.2	生成したテキスト情報と既存のテキスト情報の例 2	42
4.3	生成したテキスト情報と既存のテキスト情報の例 3	43
4.4	生成したテキスト情報と既存のテキスト情報の例 4	43
4.5	既存のテキスト情報の例	45
4.6	頻出単語	47
4.7	類型化したテンプレートのスロット	50
4.8	テンプレートの使用条件	51
4.9	生成したテキスト情報と既存のテキスト情報の例	52
4.10	評価者 10 人の評価値の平均値が最大のテキスト情報	54
4.11	評価者別の結果. 生成したテキスト情報の評価値が既存のテキスト情報より高い割合 (>), 同じ割合 (=), 低い割合 (<).	56

4.12	GPT-2による生成例と評価結果	57
4.13	生成したテキスト情報1でGPT-2の入力に使用した構造化データ (選手の情報)	57
4.14	生成したテキスト情報1でGPT-2の入力に使用した構造化データ (予測, 競輪場, ラインの情報)	58
4.15	生成したテキスト情報1でGPT-2の入力に使用したテキスト	59
5.1	各設問における評価値の平均値と中央値	66
5.2	predicting-oriented users 向けのテキスト情報の例 と各評価者の評価 値 (レース結果を予想し配当金を得ることを重視するユーザにとっ て価値のある情報か?). eval i は評価者 ID i の評価値を示す.	67
5.3	viewing-oriented users 向けのテキスト情報の例 と各評価者の評価 値 (レースを観戦し楽しむことを重視するユーザにとって価値のあ る情報か?). eval i は評価者 ID i の評価値を示す.	68

第1章

序論

1.1 研究背景

意思決定とは、複数の行動の中から効用が高いと思われる行動を一つ選択する行為である。人間は生活の中で様々な意思決定を行っており、商品の購入や休日の予定の決定にはじまり、就職先の決定や住居の決定、外出するのに傘を持っていくか否かなど様々な例が挙げられる。本論文では意思決定の主体をユーザと呼ぶ。

意思決定をする際の行動に対する効用は、ユーザがどのような情報を知っているかによって変化する。その情報を知っていたら異なる行動を選択していた、といった状況は現実には発生する状況であり、このことからユーザが意思決定をする際の行動に対する効用は、情報によって変化するということがわかる。そのため、ユーザに対して有用な情報を提示することが意思決定の支援において重要である。特に意思決定に関わる情報が多く複雑な場合は、認知能力の限界などによりユーザは与えられた情報の全てを理解することができず、不確実な将来の予測の精度の低下や納得感の低下などの影響が懸念される。

多くの現実の意思決定は多目的であり、効用は様々な要素から構成される複合的なものである。効用にはユーザの外部から与えられる金銭的な報酬や他者からの感謝といった効用やユーザの内部から発生する行動をとること自体の満足といった効用などが効用を構成する要素として考えられる。ユーザによってどのような要素を考慮するのか、またどのような要素を重視するのかについては異なることがある。そのため、ユーザにとって有用な情報もユーザごとに異なることがあるため、全てのユーザに対して同じ情報を提示するのではなく、ユーザごとに適切な情報を提示する情報提示の個人化が意思決定の支援において重要である。多様なユーザに対して有用な情報を提示するためには、有用な情報を自動生成する技術が求められる。

意思決定を支援する技術に対する社会的需要は高い [1]。国立研究開発法人科学

技術振興機構 研究開発戦略センターが発表した研究開発の俯瞰報告書 システム・情報科学技術分野（2021年）では、意思決定の支援に関する要素技術に関する研究を組み合わせる一つの支援システムとして実現する研究が求められており、どのような支援システムが有効であるのかという点についても研究課題であるとしている [2]。様々な意思決定の状況で有用な汎用的な支援システムは社会的インパクトも大きく社会的需要も高い一方で、どのような支援システムが有効であるかという点は支援の対象とする意思決定の状況によって異なることが想定される。そのため、特定の意思決定の状況をインスタンスとした研究も重要な研究成果であり、本研究分野の発展に寄与することが期待される。

1.2 研究目的

本論文では、背景で述べたような意思決定の状況を想定し、ユーザの意思決定において有用な情報を生成することを目的とする。ユーザに提示する情報の形式として、テキストやテーブル、図、チャートなど様々な形式が挙げられ、その中でもテキスト形式は様々な状況で好まれ一般的に使用される。医療の意思決定の状況では、患者の状態に関する生理学的データをテキスト形式で提示する方が、グラフ形式で提示する場合よりもより正確な意思決定が行えたという報告がある [3]。そこで本論文ではユーザに提示する情報の形式としてテキスト形式を採用し、ユーザの意思決定において有用なテキスト情報を生成することを目的とする。

有用なテキスト情報の生成のための研究項目として、テキスト情報の元となるデータの生成、データからテキスト情報の生成、テキスト情報の個人化の3つが挙げられる。本論文では、公営競技の一つである競輪の投票券購入という意思決定の状況をインスタンスとして有用な情報の生成に関する研究を実施する。競輪の投票券を購入する多くのユーザにとって重要な要素であると考えられる配当金の獲得に注目し、配当金に関連する有用なテキスト情報を生成する。配当金に関連する有用なテキスト情報の元となるデータの生成として、競輪のレース展開の予測を行う。また、ユーザの意思決定において有用な情報はユーザによって異なるという状況を考慮し、競輪において配当金の獲得と同様に重要な要素であると考えられる選手の応援に注目し、選手の応援に関連する有用な情報を生成する。配当金に関連するテキスト情報と選手の応援に関連するテキスト情報について評価実験を実施し、テキスト情報の個人化の有効性を検証する。

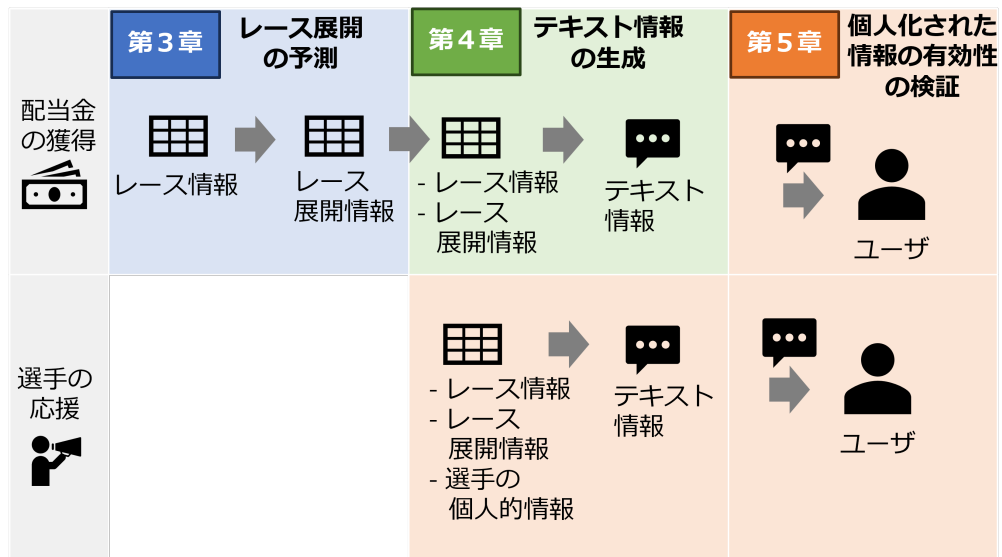


図 1.1: 本論文の構成の概略図

1.3 本論文の構成

本論文では競輪の投票券の購入という状況をインスタンスとして、ユーザの意思決定において有用な情報の生成に関する研究を実施した。本論文の構成の概略図を図 1.1 に示す。第 2 章では、本研究の関連研究について示す。第 3 章では、テキスト情報の元となるデータの生成として、競輪のレース展開の予測についての研究成果を示す。第 4 章では、ユーザの意思決定において有用な情報の生成として、第 3 章で生成したレース展開の情報やそれに関連する選手情報などを付加したテキスト情報の生成についての研究成果を示す。第 5 章では、テキスト情報の個人化についての研究成果を示す。第 6 章では、本論文のまとめと今後の展望について示す。

第2章

関連研究

2.1 意思決定に関する研究分野

本節では意思決定に関する研究分野における本論文の位置づけを示す。

2.1.1 意思決定問題について

意思決定の分類として個人の意思決定と集団の意思決定がある。個人の意思決定は、単一のユーザが自身のもつ効用関数に従って一つの行動を選択するプロセスである。一方で集団の意思決定は、複数のそれぞれ異なる効用関数をもつユーザが相互作用する状況で行動を選択するプロセスである。集団の意思決定においては合意形成の支援に関する研究 [4] や自動交渉に関する研究 [5] などが行われている。本論文では個人の意思決定を対象として、有用な情報の生成に関する研究を実施する。

将来の結果の不確実性に基ついた意思決定の分類として、確実性下の意思決定、リスク下の意思決定、不確実性下の意思決定がある [6]。確実性下の意思決定は、行動を選択して得られる効用が確実に決まっている状況での意思決定である。リスク下の意思決定は、行動を選択して得られる効用が既知の確率分布に基ついて確率的に決定する状況での意思決定である。不確実性下の意思決定は、行動を選択して得られる効用が未知の確率分布に基ついて確率的に決定する状況の意思決定である。人間が生活の中で行う意思決定の多くは不確実性下の意思決定に分類され、意思決定支援に関する研究において不確実性をもつ問題を取り扱うことは重要である。本論文では不確実性下の意思決定を対象とする。

意思決定によってユーザが獲得する効用は、大きく分けて外発的効用と内発的効用の2つが挙げられる。外発的効用とは外部から与えられる効用であり、例として給与や謝金といった金銭的報酬や他人からの感謝や評価によって得られる満足感などが挙げられる。内発的効用とは内部から発生する効用であり、ユーザが行動を選択すること自体によって得られる満足感のことを指す。外発的効用が主な効用

である意思決定の例として保有資産の増加を目的とした株式投資などが挙げられ、内発的効用が主な効用である意思決定の例として選手やチームを応援することを目的としたスポーツ観戦などが挙げられる。外発的効用は客観的に決まる傾向があり、内発的効用はユーザの主観的に決まる傾向があると考えられる。そのため、外発的効用が主となる意思決定は内発的効用が主となる意思決定よりも情報提示の個人化の必要性が低く、内発的効用が主となる意思決定は外発的効用が主となる意思決定よりも情報提示の個人化の難易度が高い。そのため、本研究で取り扱う意思決定の状況としては、外発的効用と内発的効用の両方を持つことが望ましい。本論文では公営競技の投票券購入という意思決定の状況を取り扱う。公営競技の投票券購入は、外発的効用が主となる代表例の株式投資と内発的効用が主となる代表例のスポーツ観戦の両方の要素を持つ。

2.1.2 人間の意思決定の過程

意思決定のプロセスとして、Simon は情報 (Intelligence) 活動、設計 (Design) 活動、選択 (Choice) 活動の 3 つのステップを提案した [7]。また、国立研究開発法人科学技術振興機構研究開発戦略センターは Simon の 3 ステップに対応して、状況把握・要因探索、候補の生成・評価、行動の選択・実行の 3 つのステップとして整理した [2]。本研究は、ユーザの情報活動、状況把握・要因探索のステップを支援する研究であると位置づけられる。

意思決定における規範的理論の一つとして期待効用理論が挙げられる。期待効用理論は行動に対する効用の期待値が計算可能で効用の期待値が最大となる行動を選択することで理想的な意思決定を行えるとする理論である。しかし、人間の認知能力の限界や時間や環境からの制約の影響で人間は限られた合理性しか持たず [7] (限定合理性)、期待効用理論の示す理想的な意思決定は現実には行われないとされている。行動経済学はこうした非合理的な意思決定のメカニズムを解明する研究分野である。プロスペクト理論 [8] はその代表例であり、同額の利益と損失について損失を忌避する傾向があることを明らかにし、期待効用理論では説明のつかない人間の意思決定を説明可能とした。本研究では、意思決定の主体であるユーザは限られた合理性しか持たない限定合理性を仮定する。

意思決定に関する研究として心理学や行動経済学といった分野では、意思決定の過程の解明に関する研究が行われており、人間の意思決定には様々なバイアスがかかることが報告されている。こうした人間の意思決定におけるバイアスを活用して、ユーザの意思決定を良いものへ導く分野としてナッジ [9] などの研究が行われている。ナッジは行動変容を目的とした研究と位置づけることができる一方で、本

研究はユーザの行動変容は目的ではなくユーザにとって有用な情報を提供することを目的としている。また本研究は、情報工学的アプローチによってユーザにとって有用な情報を生成する研究であると位置づけられる。

本論文では、効用が情報によって変化するという状況を取り扱うため、行動と情報の組合せによって効用が決まる効用関数 $u : A \times X \rightarrow \mathbb{R}$ によってユーザの意思決定をモデリングする。ここで、 $a \in A$ は行動、 $x \in X$ は情報を表す。ユーザは与えられた情報 x に基づき、効用 $u(a, x)$ が最大となる行動 $\operatorname{argmax}_a [u(a, x)]$ を選択する。ある行動に対する効用はどのような情報が与えられるかに依存しており、大量の情報を与えてもユーザがそれを理解できなければ効用が低くなり、ユーザが理解可能な情報を要約して与えることで効用が高くなるといった、限定合理性を仮定したユーザへの情報提示による支援をモデル化している。本論文では、こうした状況においてユーザの意思決定において有用なテキスト情報を提示することを目的とする。提示されたテキスト情報が有用であるか否かはユーザが判断する。

2.1.3 自動意思決定と意思決定支援

ユーザの意思決定への介入のアプローチは大きく分けて自動意思決定と意思決定支援の2つに分けられる [2]。ユーザの効用関数が明らかでない場合には、効用を最大化する行動を自動で選択する自動意思決定が可能である。一方でユーザの効用関数が明らかでない場合には、最終的な行動はユーザが選択するという前提のもと、意思決定において有用な情報を提示する意思決定支援が有効である。本論文で取り扱う、ユーザの意思決定において有用な情報の生成は、意思決定支援に位置づけられる。

2.2 有用なテキスト情報の生成

本節では本論文で行う有用なテキスト情報の生成についての関連研究について示す。本論文では、有用なテキスト情報の生成のための研究項目として、テキスト情報の元となるデータの生成、データからテキスト情報の生成、テキスト情報の個人化の3つを挙げた。現実の意思決定においては、不確実な将来の予測や複雑で大規模なデータからユーザ自身が必要とする情報の取得といったプロセスが必要となる。そうした現実の意思決定として、将来の株価の予測による投資銘柄の決定、将来の気象情報の予測による余暇の予定の決定、将来の渋滞状況の予測による旅程の決定、将来の商品の売り上げの予測による商品仕入の決定などが挙げられる。本論文では、将来のレース展開の予測による購入投票券の決定という現実の意思決定を対象として、有用なテキスト情報の生成についての研究を行う。

2.2.1 テキスト情報の元となるデータの生成

所与のデータを説明するテキスト情報を生成するテキスト情報の生成に関する要素技術の研究は数多く行われている。現実の意思決定において、所与のデータから予測または推論によって新しいデータの生成が求められる状況が多く存在する。テキスト情報の元となるデータの生成も有用なテキスト情報を生成するためには重要な研究項目である。テキスト情報の元となるデータの生成のための予測・推論の技術として機械学習や統計モデリング、シミュレーション、数理最適化などが挙げられる。機械学習は学習に使用する過去データが存在する場合に、高い性能を示すことが様々な分野で示されており、社会実装が進められている。機械学習の代表的なアルゴリズムとして、サポートベクターマシン (SVM) やランダムフォレスト、勾配ブースティング、ニューラルネットワークなどが挙げられる。近年では、ニューラルネットワークを使用した Deep Learning (深層学習) と呼ばれる手法が画像認識や自然言語処理をはじめとした様々な分野で成功を収めている。機械学習を活用して不確実な将来を予測する研究として、株価を予測する研究 [10, 11, 12] や気象情報を予測する研究 [13, 14], スポーツの試合結果を予測する研究 [15, 16] など様々な例が挙げられる。機械学習による予測は高い精度を示す一方で、予測器の出力する大量の数値データをユーザに提示するだけでは、意思決定の支援としては不十分であることが想定される。現在の実社会においても、大規模な数値データとして得られる気象情報の予測を気象予報士というエキスパートがユーザにとって有用な情報に変換するという処理が行われている。こうしたテキスト情報の元となるデータを生成する研究およびそのデータをユーザにとって有用なテキスト情報に変換する研究は様々な意思決定の状況で求められる研究である。

本論文ではテキスト情報の元となるデータの生成として、競輪のレース展開を予測する。競輪のレース展開の予測は、不確実な将来の予測という現実の多くの意思決定の状況と共通する特徴を持つ。競輪とよく似た競技として競馬が挙げられ、競馬に関してはレース結果を予測する研究が数多く行われている [17, 18, 19]。これらの研究では、ある1頭の馬のデータを入力として、その馬が1着になるか否かの分類や走破タイム、マージン (1着の馬との差) の回帰を行うことで、最終的なレース結果を予測している。競輪には競馬とは異なり、レース序盤から中盤にかけて、選手同士がラインと呼ばれる協力関係を結ぶ。このラインによる選手間の相互作用を考慮することが競輪のレース展開の予測において重要であることが想定される。

2.2.2 テキスト情報の生成

テキスト情報の生成には、画像からキャプションを生成する研究 [20] や発話に対する応答文を生成する研究 [21], テキストから要約文を生成する研究 [22], 機械翻訳 [23] など様々な種類が存在する. その中で, 構造化データからその説明文を生成するタスクは Data-to-Text と呼ばれる. テキスト情報の元となるデータの生成によって得られた数値データからユーザにとって有用なテキスト情報を生成するタスクは Data-to-Text に該当する. Data-to-Text については様々な研究が行われており, Data-to-Text のデータセットとして, 飲食店の説明文生成に関するデータセットである E2E NLG Challenge[24] やバスケットボールの試合結果の要約文生成のデータセットである RotoWire[25] などが挙げられる. さらに, 株価の時系列データからの概況コメントの生成 [26] や打者成績からのイニング要約文の生成 [27], 気象シミュレーション結果から気象コメントの生成 [28], 株価データから市場コメントを生成したりする研究 [29] など様々な例が挙げられる. 本論文で研究するテキスト情報の生成は, 生成の時点では明示的に与えられないテキスト情報の元となるデータの生成も行うという点で一般的な Data-to-Text とは異なるといえる.

テキスト情報の生成の手法としてニューラル言語モデルを用いた手法とテンプレートを用いた手法の2つが挙げられる.

ニューラル言語モデルを用いた手法として, Transformer[30] と呼ばれるニューラルネットワークアーキテクチャが提案されてから, BERT[31] や T5[32], GPT[33] といった Transformer を使用したモデルが提案され, テキスト情報の生成を含む様々な自然言語処理のタスクで高い精度を示した. Data-to-Text においても, GPT-2 や T5 などの事前学習済みモデルを finetune することで, 流暢で高品質なテキスト情報生成が可能であるという報告 [34, 35] がされている. ニューラル言語モデルによる生成手法は人間の手でルールを設計することなく流暢な文章を生成することが可能であるが, 生成文の制御が難しく, 事実と異なる文章を生成する場面も存在するという問題 [36, 37] も報告されている. Data-to-Text においては, ニューラル言語モデルが事実と異なる文章を生成する原因の一つとして, 学習に用いられる教師データにおいて, 入力として与えられる構造化データには含まれない情報が出力する説明文の中に記述されている点 [38] などが報告されている. 近年では, GPT-3[39] から始まり PaLM[40] や GPT-4[41], PaLM2[42] といった大規模言語モデルでは, 追加の学習をすることなく流暢で高品質なテキスト情報を生成できる. さらに, プロンプトエンジニアリングと呼ばれる手法が数多く提案されており [43, 44, 45, 46], こうした手法を組み合わせることで, より高品質なテキスト情報の生成が期待される. 一方で, 大規模言語モデルにおいても従来の言語モデルと同様

に幻覚 (Hallucination) [47] と呼ばれる、事実と異なる文章を生成するという問題もあり、Hallucination は有用なテキスト情報の生成においても重要な課題の一つである。今後のプロンプトエンジニアリングの手法や言語モデル自体の精度向上、データセットの改善などの研究によって、幻覚による不正確な出力は改善されていくことが期待される。

事前に人手で設定したテンプレートを用いた手法は、人手で適切なルールを設計するコストはかかるが、生成される文章の文法的な正確さや事実に対する正確さを保証することが容易であるという利点がある。そのため、様々なドメインで使用されている手法であり、ロボットの挨拶文の自動生成 [48] や将棋の解説文生成 [49]、EC サイトの商品紹介文の生成 [50] などに使用されている。また、レストランの説明文生成のデータセットである E2E NLG Challenge [24] においては、テンプレートを使用したルールベース手法が人間による評価において生成文の品質・自然さにおいて高い評価を得ており [51]、テンプレートを用いた手法の有効性を示している。また、コーパスからテンプレートを自動獲得する手法 [52, 27] や、ニューラル言語モデルとテンプレートを組合わせた手法 [53] などの研究も行われている。

2.2.3 個人化された情報の生成

有用な情報はユーザによって異なることが想定されるため、全てのユーザに対して同じ情報を提示するのではなく、各ユーザに適切な情報を提示する情報提示の個人化が求められる。情報提示の個人化は、広告や推薦システム [54] といった文脈において盛んに研究が行われている。広告に関する研究は、広告のコンバージョン率やクリック率といった指標を最大化する目的で実施されている点が本研究の文脈と異なる。EC サイトのアイテム推薦といった推薦システムは、ユーザに提示する情報がユーザの行動であるという点が本研究と異なる。個人化されたテキスト情報の生成についての先行研究として、サッカーの試合レポートの生成において、勝利したチームのファンと敗北したチームのファンで異なるレポートを生成する研究 [55] やがん患者へ治療後の QOL (Quality of life) についての説明文の生成する研究 [56]、EC サイトの商品紹介文の生成 [57] やニュース記事の見出しの生成 [58] などが挙げられる。こうしたユーザに対して適切な情報を提示する手法として、ユーザの過去の行動や過去に提示した情報に対するフィードバックの履歴データを使用する研究は推薦システムの文脈で盛んに研究されている。また、近年では Reinforcement Learning from Human Feedback (RLHF) という手法によって、ユーザのフィードバックの評価が高くなるようにニューラル言語モデルを学習させる研究 [59, 60] などが行われている。ChatGPT [61] は対話形式によるインタ

ラクションが可能なニューラル言語モデルを活用したサービスであり，こうした対話形式によるユーザとの双方向のインタラクションによって，ユーザに対して個人化された情報提示を実現することも期待される．一方で現実の意思決定の問題においては，ユーザのフィードバックに関する履歴データが蓄積されていない場合や，ユーザのフィードバックを収集する機構や対話形式のインタラクションによって情報提示する機構が整備されていない場合が多く存在する．そこで本論文では，ユーザのフィードバックデータを使用しない状況を想定し，システムからユーザに対する一方向の情報提示を想定したテキスト情報の生成を行う．

第3章

機械学習によるレース展開の予測

3.1 はじめに

本章では、有用なテキスト情報の元となるデータの生成として、公営競技に参加するユーザが考慮する要素の代表例である配当金の獲得において重要と考えられるレース展開を予測する。予測するレース展開は、最終半周時点で先頭の選手、1着の選手、2着の選手、3着の選手とする。不確実な将来の状況を予測する代表的な手法として、機械学習や統計モデリング、シミュレーションが挙げられる。競輪は毎日約50レース近く開催されており、予測に使用可能な過去データの量が多いという特徴がある。また、競輪とよく似た競技である競馬をはじめとしたスポーツの結果予測に関する先行研究において、機械学習を使用した予測が高い性能を示している点を考慮し、本論文では機械学習によって競輪のレース展開を予測する。

日本の公営競技におけるオッズは参加者の投票割合から計算されるパリティ方式によって計算される。オッズは参加者の投票に応じて変動し、投票締切後に実際に配当金の支払い時に使用されるオッズを確定オッズと呼ぶ。競馬ではオッズによる馬の勝利確率の推定精度が非常に高いという報告 [62] があり、オッズは優れた予測器であるともいえる。そのため、レース展開の予測精度の比較対象として確定オッズを使用した。確定オッズは予測の精度が高い一方で、公営競技において長期的な収支をプラスにするためには確定オッズと真の生起確率のギャップを見つけることが重要であるという点 [62] や確定オッズは意思決定の時点では利用することはできず、意思決定の時点で利用可能なオッズはその他のユーザの意思決定が行われないと計算されないという点、最終半周時点で先頭の選手といった投票券以外の展開に関する情報を持たないという点などから、機械学習によってレース展開を予測する手法はユーザの意思決定において有用な情報を生成するための手法として優れているといえる。

競輪とよく似た競技として競馬が挙げられ、競馬に関してはレース結果を予測

する研究が数多く行われている [17, 18, 19]. 本研究で取り扱う競輪と競馬との違いは、馬か自転車か、出走人数、開催頻度など数多くあるが、最大の違いはラインである。選手の強さや調子、ラインによる選手の相互作用を考慮することが競輪のレース展開の予測に重要であることが想定されるため、本章では競輪のレース展開に有効な予測器の入出力や入力特徴量について検討した。

本章では、3.2 節で予測器の入出力について検討した研究成果を示す。3.3 節では、最終半周時点で先頭の選手を含めたレース展開の予測についての研究成果を示す。3.4 節では、本章のまとめを示す。

3.2 予測器の入力・出力の検討

本節では、競輪のレース展開を予測するための機械学習モデルの入力と出力について検討する。入力と出力の異なる 3 つのモデルを提案し、各モデルの詳細と各モデルを比較した実験について示す。

3.2.1 提案手法

本節では簡単のため予測するレース展開を、1 着の選手、2 着の選手、3 着の選手とし、最終半周時点で先頭の選手を予測の対象外とする。そのために、車番 i が 1 着、車番 j が 2 着、車番 k が 3 着になる確率 $p(1st = i, 2nd = j, 3rd = k)$ を推定する。競輪において 1 着、2 着、3 着を着順通りに予想する賭式を車番三連勝単式（三連単）と呼ぶ。以降では、確率 $p(1st = i, 2nd = j, 3rd = k)$ を三連単的中確率と呼ぶ。

競輪とよく似た競技として競馬が挙げられ、競馬に関してはレース結果を予測する研究が数多く行われている。ニューラルネットワークを用いた予測 [17] や、サポートベクターマシンを用いた予測 [18]、ロジスティック回帰を用いた予測 [19]、ファジィ論理を用いた予測 [63] などが行われている。これらの研究では、ある 1 頭の馬のデータを入力として、その馬が 1 着になるか否かの分類や走破タイム、マージン（1 着の馬との差）の回帰を行い、レース結果を予測している。

本論文で取り扱う競輪と競馬との違いは、馬か自転車か、出走人数、開催頻度など数多くあるが、最大の違いはラインである。ラインによる選手間の相互作用を考慮することは競輪の予測において重要であると考えられる。

そこで本論文では、競馬予測に関する先行研究と同様に選手 1 人を入力とする 1 人モデルを提案するだけでなく、選手 2 人、9 人を入力とする 2 人モデルと 9 人モデルも提案し、1 人モデル、2 人モデル、9 人モデルの性能を比較する。各モデルの分類器の学習アルゴリズムとして、従来研究 [64] において良い精度を示し

た多層パーセプトロン (MLP) を用いる。

1 人モデル

1 人モデルは競馬予測に関する先行研究と同様に選手 1 人を入力として、その選手の強さを推定し、その値からレース結果を予測するモデルである。1 人モデルは次の 2 つのステップによって三連単的中確率を推定する。

1. 選手 1 人 (車番 i) を二値分類器の入力とし、車番 i が 1 着になる確率を出走選手 9 人に対して求める。
2. それらの値から三連単的中確率を近似的に計算する。

以降では、二値分類器の入出力と三連単的中確率の計算方法について説明する。

二値分類器の入力/出力 1 人モデルはレースの特徴と選手 1 人 (車番 i) の特徴を入力とする。入力 x_i の出力 y_i を車番 i が 1 着になる確率として扱う。ここで、 y_i は総和が 1 になる ($\sum_i y_i = 1$) とは限らないため、式 3.1 のような補正を行う。

$$y_i(\text{correction}) = \frac{y_i}{\sum_j y_j} \quad (3.1)$$

二値分類器の学習 入力された選手が 1 着になるかを二値分類器に学習させる。入力 x_i の教師ラベル t_i を次のように定義する。

$$t_i = \begin{cases} 0 & \text{place}_i > 1 \\ 1 & \text{place}_i = 1 \end{cases} \quad (3.2)$$

ここで、 place_i は車番 i の順位である。

三連単的中確率の計算 二値分類器の出力値を用いて三連単的中確率を近似的に計算する。車番 i が 1 着で車番 j が 2 着となる条件付き確率を、車番 i がいないレースでの車番 j の 1 着確率と考える計算手法 [65] により計算を行う。計算式を式 3.3 に示す。

$$p(\text{1st} = i, \text{2nd} = j, \text{3rd} = k) = \frac{y_i y_j y_k}{(1 - y_i)(1 - y_i - y_j)} \quad (3.3)$$

2 人モデル

2 人モデルは選手 2 人を比較することによって、レース結果を予測するモデルである。このモデルは次の 2 つのステップによって三連単的中確率を推定する。

1. 選手 2 人 (車番 i , 車番 j) を二値分類器の入力とし, 車番 i が車番 j よりも上位になる確率を出走選手 9 人の全ペアに対して求める.
2. それらの値から三連単的中確率を近似的に計算する.

以降では, 二値分類器の入出力と三連単的中確率の計算方法について説明する.

二値分類器の入力/出力 2 人モデルはレースの特徴と選手 2 人 (車番 i , 車番 j) の特徴を入力とする. 入力 $x_{i,j}$ の出力 $y_{i,j}$ は, 車番 i が車番 j より上位になる確率として扱う. ここで, 出力値は $y_{i,j} \neq 1 - y_{j,i}$ となっているため, 集計時に式 3.4 のような補正を行う.

$$y_{i,j}(\text{correction}) = \frac{y_{i,j} + (1 - y_{j,i})}{2} \quad (3.4)$$

二値分類器の学習 入力された 2 人の選手のどちらが上位になるかを二値分類器に学習させる. 入力 $x_{i,j}$ の教師ラベル $t_{i,j}$ を次のように定義する.

$$t_{i,j} = \begin{cases} 0 & \text{place}_i > \text{place}_j \\ 1 & \text{place}_i \leq \text{place}_j \end{cases} \quad (3.5)$$

また, 着順の上位 3 人を予測するための学習データとして, 4 着から 9 着の選手同士を比較したデータは学習の妨げになることが考えられる. そのため本稿では, 4 着から 9 着同士を比較したデータ以外のデータを学習に使用する. 後述する比較では, 全データを学習に使用したモデルを 2 人, 4 着から 9 着の選手同士を比較したデータを学習に使用しないモデルを 2 人_学習データ選別と表記する.

三連単的中確率の計算 二値分類器の出力値を用いて三連単的中確率を近似的に計算する. 次の 3 つの確率をそれぞれ計算し, その積によって三連単的中確率を計算する.

- $p(\text{1st} = i)$
 - 車番 i が 1 着になる確率
- $p(\text{2nd} = j | \text{1st} = i)$
 - 車番 i が 1 着の時, 車番 j が 2 着になる確率
- $p(\text{3rd} = k | \text{1st} = i, \text{2nd} = j)$
 - 車番 i が 1 着, 車番 j が 2 着の時, 車番 k が 3 着になる確率

車番 i が 1 着になる確率は、車番 i がその他の選手全員に勝つ確率、車番 i が 1 着の時、車番 j が 2 着になる確率は、車番 j が車番 i 以外の全員に勝つ確率であるという考えから各確率を式 3.6, 3.7, 3.8 で計算する。また、計算された値の総和が 1 になる ($\sum_i p(\text{1st} = i) = 1$) ように正規化を行う。

$$p(\text{1st} = i) = \frac{\prod_{m \neq i} y_{i,m}}{\sum_l (\prod_{m \neq l} y_{l,m})} \quad (3.6)$$

$$p(\text{2nd} = j | \text{1st} = i) = \frac{\prod_{m \neq i,j} y_{j,m}}{\sum_l (\prod_{m \neq i,l} y_{l,m})} \quad (3.7)$$

$$p(\text{3rd} = k | \text{1st} = i, \text{2nd} = j) = \frac{\prod_{m \neq i,j,k} y_{k,m}}{\sum_l (\prod_{m \neq i,j,l} y_{l,m})} \quad (3.8)$$

9 人モデル

9 人モデルは、選手 9 人を比較することによってレース結果を予測するモデルである。このモデルは、1 人モデルや 2 人モデルのような 2 段階の処理は行わずに多クラス分類器によって三連単的中確率を直接出力する。

多クラス分類器の入力/出力 9 人モデルはレースの特徴と選手 9 人 (車番 1, 車番 2, ..., 車番 9) の特徴を入力とする。対応する選手のない入力値は 0 とする。このモデルは、多クラス分類器によって三連単的中確率を直接出力する。出力 y は $y[\text{index}(i, j, k)] = p(\text{1st} = i, \text{2nd} = j, \text{3rd} = k)$ となる 504 次元のベクトルである。 $\text{index}(i, j, k)$ を式 3.9 で定義する。

$$\begin{aligned} \text{index}(i, j, k) &= (i - 1) \times 56 + (j - 1) \times 7 + (k - 1) \\ &\quad - d_1 - d_2 - d_3 \\ d_1 &= \begin{cases} 0 & i > j \\ 7 & i \leq j \end{cases} \\ d_2 &= \begin{cases} 0 & i > k \\ 1 & i \leq k \end{cases} \\ d_3 &= \begin{cases} 0 & j > k \\ 1 & j \leq k \end{cases} \end{aligned} \quad (3.9)$$

式 3.9 は、選手 9 人から 3 人の車番を選んで得られる順列 (i, j, k) を 3 桁の数値 $(100i + 10j + k)$ として昇順に並べることで 0 から 503 の値を割り当てている。

多クラス分類器の学習 多クラス分類器に上位3人の選手の順序を学習させる。学習に用いる教師ラベル t は正解の三連単を表すワンホットベクトルであり式 3.10 となる。

$$t[\text{index}(1\text{st}, 2\text{nd}, 3\text{rd})] = 1 \quad (3.10)$$

また、9人モデルの学習データは通常1レースに対して1つであり、1人モデルや2人モデルと比較すると入力複雑さに対して学習データ数が少ないということが考えられる。そこで本稿では、選手の車番をランダムに入れ替えたデータを学習データに加えることでデータを増量する。本稿ではこれによって学習データ数を8倍に増量した。後述する比較では、データ増量を行わないモデルを9人と表記し、データ増量を行ったモデルを9人_学習データ増量と表記する。

3.2.2 2人モデル・9人モデルの比較

本節では複数の選手を入力とする2人モデルと9人モデルの性能をシンプルな設定で比較した実験について示す。本実験の目的は2人モデルと9人モデルがそれぞれの程度の予測精度を示すのかを明らかにすること、また各モデルの予測精度の違いを比較することである。

実験設定

データ 2014年から2016年の間に日本で実施されたレースのデータを使用した。2014年と2015年のデータは訓練データとして使用し、2016年のデータはテストデータとして使用した。訓練データは40,230レースあり、テストデータは15,731レースある。本論文では、以下の条件を満たすデータを用いる。

- 男性レース
- 競り無し
- 同着なし
- 欠損なし

特徴量 ニューラルネットワークの入力として、レース特徴と選手特徴とライン特徴を使用する。各特徴量の詳細を表 3.10 に示す。車番と年齢以外の選手特徴は過去4ヶ月のデータである。ライン特徴は、ラインの影響を予測するための特徴である。各モデルは、そのモデルに適した異なるライン特徴を使用した。2人モデルは、先行選手の選手特徴をライン特徴として使用した。2人モデルは比較する2人の選手が同じラインか否かを表す特徴も使用した。9人モデルは、ラインベクトル

表 3.1: 入力特徴量

レースについての特徴量	レースの格
	トラックの周長
	レースの出走人数
選手についての特徴量	車番
	年齢
	競走得点
	1 着回数
	2 着回数
	3 着回数
	1 着率
	2 連帯率
	バック取り回数
	決まり手回数
	ラインについての特徴量
ライン内での自身の位置	
先行選手の選手についての特徴量 (2 人モデルで使用)	
ラインが同じか否か (2 人モデルで使用)	
ラインベクトル (9 人モデルで使用)	

を使用する. 1-9-3 で表されるラインに所属する選手についてのラインベクトルは $[1, 0, 1, 0, 0, 0, 0, 0, 1]$ になる. 2 人モデルの入力は 64 次元で, 9 人モデルの入力は 219 次元である.

表 3.2: ハイパーパラメータの探索範囲

hyperparameter	search range
activate function	ReLU
mini batch size	256
drop out	0.5
optimizer	Adam [66]
learning rate	0.001, 0.0001, 0.00001
hidden layer	$[2^n], [2^n, 2^n], [2^n, 2^n, 2^n]$ ($n=7,8,9$)

表 3.3: 2人モデルのハイパーパラメータ

hyperparameter	selected
activate function	ReLU
mini batch size	256
drop out	0.5
optimizer	Adam
learning rate	0.0001
hidden layer	$[2^n]$ ($n=8$)
epoch	210

比較 2人モデルと9人モデルについて、1着選手、2着選手、3着選手の的中精度を比較した。1着選手については、Top-K-accuracy($K=1,2,3$)を使用した。1着選手と2着選手については、Top-K-accuracy($K=2,3$)として、1着選手として予測された上位K人が、実際に1着または2着になっている場合を正解とした。1着選手、2着選手、3着選手については、Top-K-accuracy($K=3$)として、1着選手として予測された上位K人が、実際に1着または2着または3着になっている場合を正解とした。また、1着選手、2着選手、3着選手については、三連単の的中精度でも評価を行い、Top-K-Accuracy($K=1$)を使用した。

訓練データの2割をバリデーションデータにして、ニューラルネットワークのハイパーパラメータを決定した。ハイパーパラメータの探索範囲 3.2 を表に示す。2人モデルと9人モデルはどちらも MLP(Multi-layer perceptron) によって構築した。2人モデルのハイパーパラメータを表 3.3 に、9人モデルのハイパーパラメータ 3.4 を表に示す。表 3.2, 3.3, 3.4 において、 $[2^n, 2^n]$ は隠れ層が2層有り、各ユニット数が 2^n であることを意味する。

表 3.4: 9 人モデルのハイパーパラメータ

hyperparameter	selected value
activate function	ReLU
mini batch size	256
drop out	0.5
optimizer	Adam
learning rate	0.0001
hidden layer	$[2^n, 2^n]$ ($n=8$)
epoch	200

結果・考察

結果を表 3.7 に示す. 9 人モデルの方が 2 人モデルよりも三連単と 1 着, 2 着, 3 着の選手の的中精度が高く, 2 人モデルの方が 9 人モデルよりも 1 着の選手と 1 着, 2 着の選手の的中精度が高いことが確認された. 2 人モデルが 1 着の選手の的中精度が高い理由として, 入出力の単純さと学習データ量の多さが考えられる. 2 人モデルは三連単といった複雑な予測については精度が低く, 選手 9 人を入力とする 9 人モデルが高い精度を示しており, 選手 9 人を入力とする方式の有効性が示唆された. 一方で, 選手 9 人を入力する 9 人モデルはその入出力の複雑さと学習データ量の少なさから, 1 着の選手の精度は高くない. 効率的に選手 9 人の情報を処理する機構や学習データ量を増加させる工夫などの適用によって, 9 人モデルを用いたより高精度なモデルの開発が期待される. 3.2.3 節では 9 人モデルに対し学習データ量を増加させる手法を適用し, 3.3 節では効率的に選手 9 人を処理可能であると期待される Transformer を適用する.

3.2.3 1 人モデル・2 人モデル・9 人モデルの比較

本節では, 3.2.2 節で比較した 2 人モデルと 9 人モデルに加えて, 1 人モデルを比較した実験について示す. また 3.2.2 節に加えて, 各モデルで使用する特徴量を統一した場合の比較や各モデルにおいて有効と思われる学習データの増量または選別手法を適用した場合の比較を行う. 本実験の目的は各モデルの予測精度を比較することである.

実験設定

本節では, 学習とテストに使用したデータ, 予測に使用する特徴量, 予測手法の性能を比較する項目について示す.

表 3.5: 結果

三連単			
2人モデル	4.9 %		
9人モデル	5.6 %		
	top 1 (1st)	top 2 (1st)	top 3 (1st)
2人モデル	40.0 %	60.5 %	72.7 %
9人モデル	34.9 %	51.5 %	60.0 %
	top 2 (1st,2nd)	top 3 (1st,2nd)	
2人モデル	24.2 %	42.2 %	
9人モデル	23.8 %	36.3 %	
	top 3 (1st,2nd,3rd)		
2人モデル	13.2 %		
9人モデル	15.2 %		

データ 2014年から2016年の間に実施されたレースのデータを使用した。2014年と2015年のデータを訓練データとして使用し、2016年のデータはテストデータとして使用した。各レース数は訓練データが40,230レースで、テストデータが15,731レースである。また、訓練データの2割を検証データとして各モデルのハイパーパラメータを決定した。本稿では、以下の条件を満たすデータを使用した。

- 男性レース
- 競り無し
- 同着無し
- 欠損値無し

女性レース（ガールズ競輪）も存在するが、ガールズ競輪にはラインが存在せず競技として男性レースと大きく異なり、レース数も比較的少ないため本稿では対象外とした。競りとは、ライン内で自分が有利な位置につくためにライン内の位置を複数人で奪い合うことを意味する。競りに勝った選手はその位置につくことができるが、負けた選手はその位置につくことができない。そのため、競りがあるレースはラインがレース前に確定しないので、本稿では対象外とした。同着レースのデータは同着なしのデータと同様に教師ラベルを付与することが出来ない。また、同着レースのデータ数も少ないため本稿では対象外とした。欠損値とは、特徴量として過去4ヶ月の成績などを用いているため、過去4ヶ月レースに参加していない選手は、その成績が無い場合欠損値となる。同着レース同様に対象となるデータ数が少なかったため本稿では対象外とした。

特徴量 レースに関するデータ（レース特徴）と選手に関するデータ（選手特徴）を予測に用いた。また、選手に関するデータとして選手個人に関するデータ（個人特徴）と選手の所属するラインに関するデータ（ライン特徴）を用いた。本稿では、インターネット上で誰でも閲覧可能なデータを予測に用いた。特徴量の詳細を表 3.10 に示す。

レース特徴はレースに関する特徴であり、日付とバンクの長さを使用した。バンクの長さは 333m,335m,400m,500m の 4 種類がある。1 人モデルでは、同じレースに出走する他の選手と比較するための特徴として、同じレースに出走する選手の各個人特徴の平均値を用いた。

個人特徴は、選手個人についての特徴である。年齢以外の個人特徴は選手の強さを推定するのに有効であると考えられる特徴を採用しており、過去 4 ヶ月の成績データに基づいて算出されている。競争得点はレースの成績によって選手に与えられる点である。バック取り回数は最終半周の時点で先頭を走っていた回数のことである。決まり手はレースの決着のつき方であり、逃げ・捲り・差し・マークの 4 種類があり、決まり手回数はそれぞれの回数のことである。

ライン特徴は、ラインの影響を考慮するための特徴量である。ライン特徴に関しては、1 人モデル、2 人モデル、9 人モデルのそれぞれで異なる特徴量が用いられる。（一部同じ特徴量を用いる。）先行選手か否か、自身の所属するラインの人数、ライン内で自身の前にいる選手の数に関しては、3 つの予測モデルで同じ形式の特徴量が利用される。先行選手か否かは、先行選手の場合は 1、そうでない場合は 0 となる。

先行選手の個人特徴は、1 人モデルでは先行選手の個人特徴を用いた。2 人モデルでは先行選手の個人特徴と比較する 2 人の選手が同じラインか否かを表す特徴を用いた。

ラインが同じか否かは、2 人モデルのみに用いられて、選択された 2 人が同じラインの場合は 1、それ以外は 0 となる。ラインベクトル、前方選手ベクトル、後方選手ベクトルは 9 人モデルのみに用いられ、自身のラインと前後の選手を表すためのベクトルで表現される。例えば、ラインが 1-9-3 の場合、車番 9 のラインベクトルは $[1, 0, 1, 0, 0, 0, 0, 0, 1]$ 、前方選手ベクトルは $[1, 0, 0, 0, 0, 0, 0, 0, 0]$ 、後方選手ベクトルは $[0, 0, 1, 0, 0, 0, 0, 0, 0]$ となる。前方または後方の選手がいない場合はゼロベクトルを用いた。

後述する比較では、各モデルで共通しているライン特徴のみを使用したモデルを比較に使用し、1 人_共通ライン特徴のように表記する。9 人モデルについては 1 人、2 人モデルと同じ先行選手の個人特徴をライン特徴として使用したモデルも比較に使用し、9 人_先行ライン特徴と表記する。

表 3.6: 入力特徴量

レース特徴	日付 バンクの長さ 同じレースに出走する選手の各個人特徴の平均値 (1 人モデル)
個人特徴	年齢 競走得点 1 着回数 2 着回数 3 着回数 1 着率 2 連対率 バック取り回数 決まり手回数
ライン特徴	先行選手か否か 自身の所属するラインの人数 ライン内で自身の前にいる選手の数 先行選手の個人特徴 (1 人, 2 人モデル) ラインが同じか否か (2 人モデル) ラインベクトル (9 人モデル) 前方選手ベクトル (9 人モデル) 後方選手ベクトル (9 人モデル)

各特徴量は最大値 1, 最小値 0 に正規化して入力に使用した。1 人モデルはレース特徴と 1 人の選手特徴を結合した 42 次元ベクトル, 2 人モデルはレース特徴と 2 人の選手特徴を結合した 62 次元ベクトル, 9 人モデルはレース特徴と 9 人の選手特徴を結合した 381 次元ベクトルを入力ベクトルとした。

比較 各種モデルについて, 1 着選手, 二車単, 三連単の的中精度, 二車単と三連単の回収率, 三連単の的中確率の推定誤差を比較した。二車単とは 1 着, 2 着を着順通りに予想する賭式である。的中精度については, Top-K-accuracy を用いた。1 着選手については $K=1, 2, 3$, 二車単と三連単については $K=1, 5, 10$ の Top-K-accuracy を用いた。回収率は的中確率が最大の車券を各レースで 1 点ずつ購入した場合の総配当金を総購入費で除算した値であり, 配当の計算には確定オッズを使用した。三

表 3.7: 予測モデルの比較 (1 着, 二車単, 三連単の Top K accuracy)

	1 着 @1 [%]	1 着 @2 [%]	1 着 @3 [%]	二車単 @1 [%]	二車単 @5 [%]	二車単 @10 [%]	三連単 @1 [%]	三連単 @5 [%]	三連単 @10 [%]
1 人	41.8	62.8	76.2	13.7	42.7	60.0	3.3	12.7	20.9
1 人_共通ライン特徴	41.2	62.6	76.1	13.6	42.4	60.0	3.3	12.6	20.7
2 人	39.4	60.4	73.2	15.7	43.4	59.5	4.8	17.1	26.7
2 人_共通ライン特徴	39.2	59.9	73.2	14.3	41.9	58.8	4.1	15.5	24.7
2 人_学習データ選別	41.7	62.6	75.6	16.7	45.5	61.6	5.1	17.6	27.4
9 人	36.8	57.7	72.4	17.9	46.0	62.3	6.3	18.8	28.4
9 人_共通ライン特徴	38.3	60.0	73.6	13.7	41.7	58.4	3.4	13.6	22.9
9 人_先行ライン特徴	36.8	57.1	70.9	7.8	26.5	42.9	2.7	11.5	29.3
9 人_学習データ増量	40.6	61.8	75.5	19.1	50.4	66.8	7.7	22.8	33.4
オッズ	—	—	—	21.2	52.6	68.9	9.1	26.2	37.2

連単的中確率の推定誤差は次の手順で計算した。

1. 三連単的中確率の推定値の小数点第 3 位以下を切り捨てる。
2. 小数点第 3 位以下を切り捨てた各数値ごと (0.00, 0.01, 0.02, ..., 0.99) に、正解の三連単をもとに実際の三連単的中確率を計算する。
3. その平均絶対誤差 (MAE) を計算する。

三連単的中確率は値が高くなるにつれて発生頻度も少なくなるため、本稿では 0.2 以下の三連単的中確率を誤差計算の対象とした。また、横軸を推定確率、縦軸を実際の的中確率としたグラフによりその関係を示す。

予測のベースラインとして、確定オッズによる予測を用いた。オッズとは公営競技における払戻金の倍率であり、投票券の投票数によって決定される。投票数の多い (人気の高い) 投票券のオッズは低く、投票数の少ない (人気の低い) 投票券のオッズは高くなる。つまり、オッズは投票者全体の予想を反映していると考えることができる。

結果・考察

各モデルとオッズの 1 着予測, 二車単予測, 三連単予測の Top-K-accuracy を表 3.7 に示す。各モデルの計算する三連単的中確率の推定の平均絶対誤差を表 3.8 に示し、その中の 1 人, 2 人, 9 人について、推定値と真値についての関係を図 3.1 に示す。各モデルとオッズの二車単, 三連単の回収率を表 3.14 に示す。

ライン特徴についての比較 各モデルについて共通のライン特徴のみを使用するモデルとモデル特有のライン特徴を使用するモデルを比較する。表 3.7 から 1 人モ

デルについては、先行選手の個人特徴をライン特徴に使用することによる精度の違いは確認できない。2人モデルについては、先行選手の個人特徴をライン特徴に使用することで、1着については精度の違いは確認できないが、二車単、三連単の精度の向上が確認できる。二車単、三連単というラインの影響を強く受ける項目における精度の向上は、使用したライン特徴が競輪固有の問題であるラインの扱いにおいて有効であることを示している。9人モデルについては、ラインを表現する3種のベクトルをライン特徴に使用することで二車単、三連単の精度が向上しており、使用した特徴のラインの扱いにおける有効性を示しているが、1着については精度が低下している。1着予測という二車単、三連単と比較してラインの影響の小さい単純なタスクにおいては、ライン特徴追加による入力複雑化のデメリットが大きかったと考えられる。9人モデルにおいて、1人モデルらと同様に先行選手の個人特徴をライン特徴に使用すると、精度が著しく低下することからも、9人モデルの二車単、三連単の精度について、ライン特徴として使用したベクトルの貢献が大きいことがわかる。

各モデルについての比較 表3.7から各モデル(1人, 2人, 9人)を比較すると、二車単、三連単については、9人モデルが最も精度が高いことが確認できる。三連単については表3.8, 図3.1から、9人モデルが最も正しく確率を推定可能であることが確認できる。一方で、共通のライン特徴を使用したモデルを比較すると、9人モデルの精度は低いことが確認できる。

9人モデルは出走選手全員のデータを1つの入力として扱うことで、その選手らの関係性を表現するベクトルを入力に取り入れることが可能である。そのため、ラインを考慮した予測が他モデルより高精度で行えたものと考えられる。その一方で、9人モデルの1着精度がライン特徴の追加によって低下したことや、1着の精度については1人モデルが最も精度が高いことから、9人モデルの出走選手全員のデータを1つの入力とする方法には改善の余地があると考えられる。具体的には、1人モデルの枠組みを用いた、各選手単位での特徴抽出による選手のベクトル表現に対して、9人モデルの枠組みを適用することで、さらなる精度向上が期待できる。

2人モデルはどの項目においても最高精度を示すことはない。しかし、共通のライン特徴を用いた場合の三連単の精度については、最も精度が高いことが確認でき、選手を1対1で比較するという枠組みを用いて得られる特徴は予測に有効と考えられる。今後は、選手のベクトル表現を得る際に、2人モデルの枠組みを組み込むことも検討する。

表 3.8: 予測モデルの比較 (三連単的中確率の推定誤差)

	MAE
1人	0.037
1人_共通ライン特徴	0.038
2人	0.054
2人_共通ライン特徴	0.059
2人_学習データ選別	0.061
9人	0.010
9人_共通ライン特徴	0.051
9人_先行ライン特徴	0.046
9人_学習データ増量	0.018

学習データ選別・増量についての比較 2人モデルと9人モデルの学習データ選別、学習データ増量について比較すると、どちらも選別、増量を行わないモデルよりも精度の向上が確認された。特に9人モデルのデータ増量は、1着の Top-K-accuracy を約4%向上させるなど、大きく精度を向上させた。一方で表3.8の確率の推定誤差に注目すると、データ選別、データ増量を行ったモデルは誤差が僅かに増加して

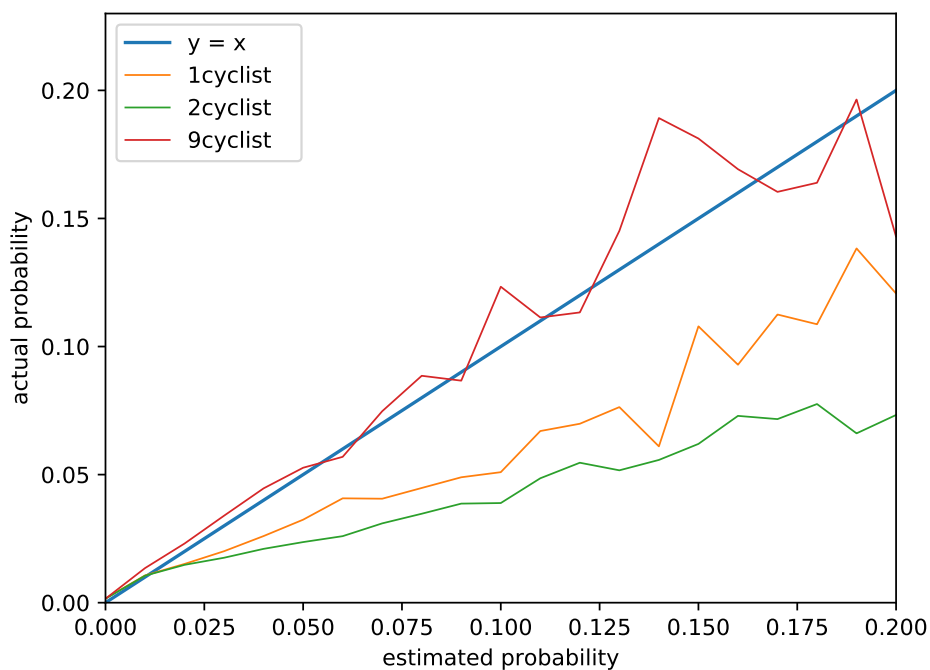


図 3.1: 予測モデルの比較 (三連単的中確率の推定精度)

表 3.9: 予測モデルの比較 (回収率)

	二車単回収率 [%]	三連単回収率 [%]
1 人	83.6	74.0
1 人_共通ライン特徴	83.3	71.6
2 人	82.1	71.8
2 人_共通ライン特徴	82.0	81.8
2 人_学習データ選別	79.3	69.6
9 人	89.0	92.1
9 人_共通ライン特徴	79.5	71.3
9 人_先行ライン特徴	75.0	73.9
9 人_学習データ増量	83.9	93.2
オッズ	78.4	81.5

いる。データ増量は的中精度の面では非常に効果的であったが、確率の推定精度に及ぼす影響について今後調査する必要がある。また、適切なデータ増量数の調査も今後の課題である。

オッズについての比較 オッズと各モデルを比較すると、オッズの予測精度が高いことが確認できる。競馬ではオッズの馬の勝利確率の推定精度が非常に高いという報告 [62] もあり、オッズは優れた予測器であるとも言える。しかし、競輪の投票券の購入者は利益を得ることを目的としているため、テキスト情報生成のための予測には予測精度だけでなく回収率という指標も考慮する必要がある。表 3.7 の結果はオッズが最小の投票券の的中率であり、その配当は低い。また表 3.14 に示したように機械学習による予測（特に 9 人モデル）は、オッズによる予測よりも高い回収率を示す。

またオッズは、観客の投票がなければ決定されない。出走選手は基本的にはレース前日の夜には公開されており、その時点ではオッズを用いて予測を行うことは出来ない。

また、オッズは観客の投票によって決定されるため、投票締切前まで変動し続ける。そのため、注目度の低く票のあまり集まらないレースでは、オッズによる予測結果は時間経過に伴って大きく変動することもある。一方で、本稿で提案した予測手法の利点として、本稿で提案した予測手法は時間経過に伴って変動することはなく、投票が無くても予測結果を出力可能であることが挙げられる。このように、本稿で提案した予測手法は、的中率に限ればオッズに劣っているものの、回収率、

予測結果の安定性、予測結果を出力可能なタイミングといった条件を考慮すると、テキスト情報の生成のための予測としてオッズより優れていると考えられる。

3.3 レース展開の予測

本節では、最終半周時点で先頭の選手を含むレース展開の予測器について示し、確定オッズとの比較によって予測器が有用なテキスト情報の生成のための十分な性能であることを示す。

3.3.1 問題設定

競輪において、最終半周時点で先頭であることをバック取りと呼ぶ。本稿では、テキスト情報にレース展開を記述するために、バック取りおよび1・2・3着の選手を予測する。

予測には、レース開始前に観測可能な情報のみを使用する。出場選手ごとの特徴ベクトルが \mathbf{x}_i で表され、予測器にはレースに出場する全ての選手についての特徴ベクトルの系列が入力される。ここで、 i は出場選手のレース中の車番を表す。特徴ベクトル \mathbf{x}_i は全選手で共通の値となる共通特徴 \mathbf{x}^c と選手の過去成績などの各選手によって異なる値となる個人特徴 \mathbf{x}_i^p 、ラインなどのその他の出場選手との関係性を表す関係性特徴 $\mathbf{x}_{i,j}^r$ の3種類のベクトルで構成される。ここで、 \mathbf{x}_i^p は車番 i の個人特徴、 $\mathbf{x}_{i,j}^r$ は車番 i から見た車番 j の関係性特徴である。

予測するレース結果は系列 $\mathbf{y} = [y_0, y_1, y_2, y_3]$ で表す。ここで、 y_0 はバック取り選手の車番、 y_1, y_2, y_3 は1, 2, 3着の選手の車番である。予測器は、任意の \mathbf{y} で表されるレース結果の生起確率を計算する。

3.3.2 提案手法

時系列予測に用いられる機械学習モデルとして、再帰型ニューラルネットワーク (RNN, LSTM[67]) や Transformer[30] などが挙げられる。Transformer は自然言語処理の分野で、再帰型ニューラルネットワークに代わり、現在一般的に用いられているモデルであり、近年では時系列予測 [68, 69] や画像認識 [70] など様々な分野でその有効性が示されているため、競輪のレース結果の予測においても高い精度を示すことが期待できる。本稿ではレース結果の系列 \mathbf{y} の予測に Transformer を適用する。

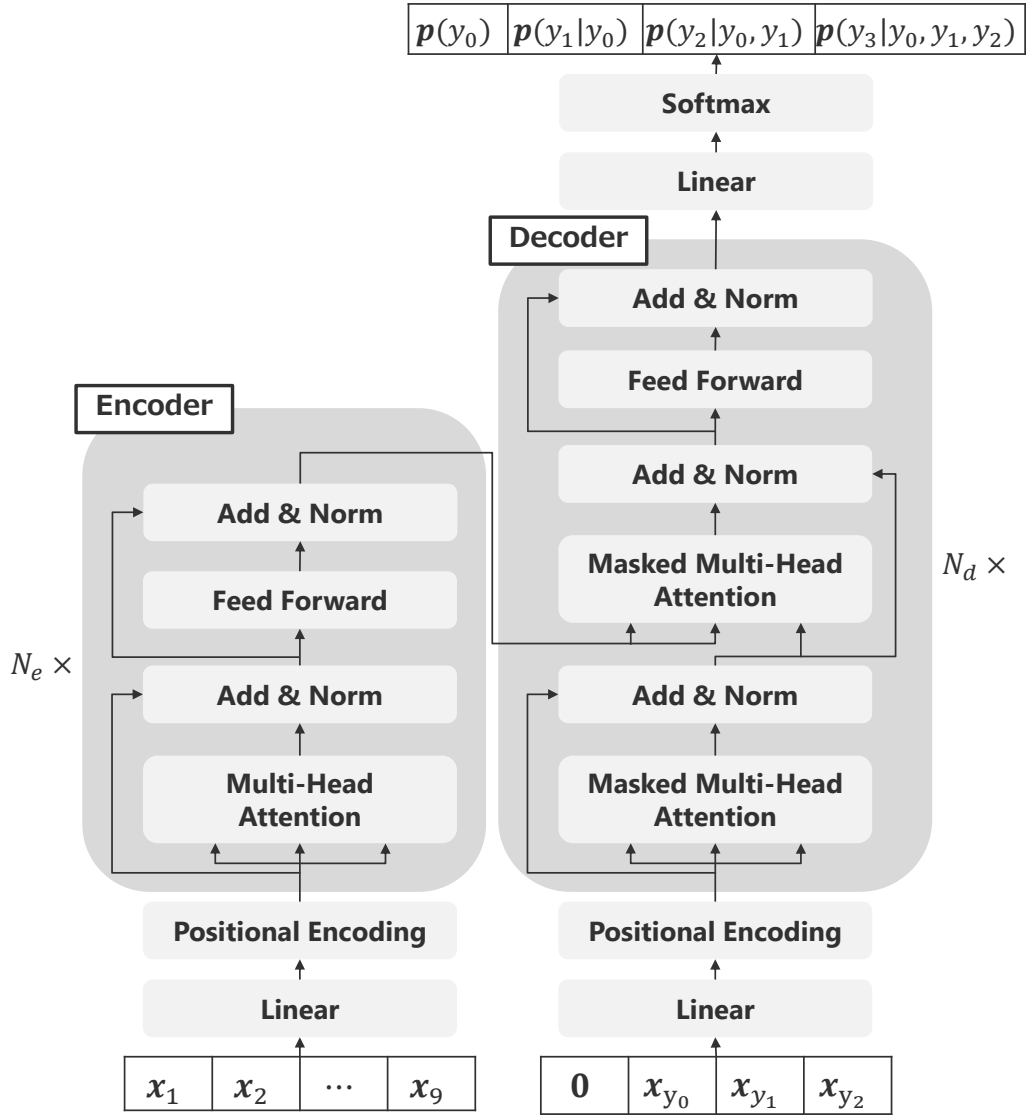


図 3.2: Transformer による予測器の概略図

Transformer モデルを用いた予測器の構造

Transformer による予測器の概略図を図 3.2 に示す。Encoder には選手の特徴ベクトル \mathbf{x}_i の系列を入力し、Decoder には各系列 \mathbf{y} に対応する選手の特徴ベクトルを入力する。Encoder と Decoder の入力に使用する車番 i の選手の特徴ベクトル \mathbf{x}_i は式 3.11 に示すように、共通特徴 \mathbf{x}^c 、個人特徴 \mathbf{x}_i^p 、関係性特徴 $\mathbf{x}_{i,j}^r$ を結合したベクトルである。

$$\mathbf{x}_i = (\mathbf{x}^c, \mathbf{x}_i^p, \mathbf{x}_{i,1}^r, \mathbf{x}_{i,2}^r, \dots, \mathbf{x}_{i,9}^r) \quad (3.11)$$

Decoder の出力はそれぞれ、バック取り選手の確率分布 $\mathbf{p}(y_0)$ 、バック取り選手で条件づけた 1 着選手の確率分布 $\mathbf{p}(y_1|y_0)$ 、バック取り選手と 1 着選手で条件づけた 2 着選手の確率分布 $\mathbf{p}(y_2|y_0, y_1)$ 、バック取り選手と 1 着選手と 2 着選手で条件づけた 3 着選手の確率分布 $\mathbf{p}(y_3|y_0, y_1, y_2)$ である。

Encoder と Decoder の構造は, Vaswani らによって提案された構造 [30] を用いる. Encoder の層数は $N_e = 6$, Decoder の層数は $N_d = 4$ として, 各層で同じ構造を使用した. Feed Forward 層の中間層の次元は $d_f = 256$, Multi-Head Attention のヘッド数は $h = 1$ として, Encoder と Decoder で共通の値を使用した. また, Encoder と Decoder への入力前に線型結合 (Linear) 層を導入し, 出力次元は $d_l = 128$ とした. 1 着選手を予測する際の 2 着選手の情報といった, 予測時に本来観測できない未来の情報を無視するように, Decoder では Masked Multi-Head Attention を使用した.

予測器の学習

ミニバッチサイズを 512, Optimizer として RAdam [71] ($\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$) を用い, 学習率の初期値は $lr_{init} = 0.001$ を使用して予測器を学習した. 検証データに対する誤差が 10 エポック続けて改善しなかった場合に学習率を 0.1 倍し, 30 エポック続けて改善しなかった場合に学習を終了することとした. エポック毎に検証データに対する誤差を計算し, 誤差が最小となるエポックでの結合重みを最終的な予測器として選択した. 損失関数は式 3.12 に示すクロスエントロピーを使用した. ここで, l は予測対象の系列長を表し, 本稿では $l = 4$ とする. また $t = [t_0, t_1, t_2, t_3]$ は正解の系列を表す.

$$L = -\frac{1}{l} \sum_{i=0}^l \log p(y_i = t_i | y_{0:i-1} = t_{0:i-1}) \quad (3.12)$$

また学習時のデータ拡張 (Data Augmentation) として, ミニバッチ選択時に各データの選手の車番をランダムに入れ替える操作を行った. 車番のランダムな入れ替えは, 3.2.3 節でその有効性が確認されている. 推論時には, ランダムな入れ替えを 100 回繰り返した平均値を最終的な予測器の出力とした.

3.3.3 予測精度の検証

本節では, 3.3.2 節で示した Transformer による予測器の性能を検証する実験について示す. 本実験の目的は, Transformer による予測器が確定オッズよりも高い予測精度を示すかどうか, また確定オッズとの中確率によって計算される配当金の期待値に基づいて投票券を購入することで回収率 100% を達成可能かを明らかにすることである.

実験設定

データ 2013 年 6 月 1 日から 2019 年 6 月 1 日の間に実施された男性選手のレースのうち, 選手の失格, 落車が発生したレース (全体の約 7%) を除外したデータを

表 3.10: 特徴量

x^c	<p>日付</p> <p>競輪場の情報</p> <p>1着選手に与えられる競争得点</p>
x^p	<p>年齢</p> <p>先行選手か否か</p> <p>ライン内で自身の前にいる選手の数</p> <p>直近 120 日の成績</p> <p>直近 1095 日の成績</p> <p>直近 3 レースの順位, 競争得点, バック取り</p> <p>直近 10 レースの連勝成績</p>
x^r	<p>同じラインの選手</p> <p>同じラインの前方選手</p> <p>同じラインの後方選手</p>

使用した。女性選手のレースについては、ラインが存在しない点と開催数が男性選手のレースと比較して少ない（全体の約 5%）点から本稿では対象外とした。2013 年 6 月 1 日から 2018 年 5 月 31 日のデータを訓練データとして使用し、2018 年 6 月 1 日から 2019 年 5 月 31 日のデータはテストデータとして使用した。各レース数は訓練データが 101,698 レースで、テストデータが 19,759 レースである。また、訓練データの 1 割を検証データとして各モデルのハイパーパラメータを決定した。

予測器に入力される特徴量 予測器への入力として使用した特徴量を表 3.10 に示す。

共通特徴 x^c では、日付と競輪場の情報、1 着選手に与えられる競争得点を使用した。競輪場の情報として、バンクの周長、直線部分の長さ、傾斜の角度といった情報を使用した。競争得点はレースの成績によって選手に与えられる点数である。

個人特徴 x^p では、年齢やライン内での位置に関する情報、直近 N 日 ($N = 120, 1095$) の成績、直近 N レース ($N = 3, 10$) の成績を使用した。直近 N 日の成績として n 着割合 ($n = 1, 2, 3, 4, 5$) と平均競争得点、SHB 割合、決まり手割合を使用した。また成績に加えて、過去に出場したレースの情報も使用し、出場選手数の平均、1 着選手に与えられる競争得点の平均、30 日当たりの出場レース数を使用した。直近 120 日の成績については、直近 120 日に出場した全レースの成績に加えて、所属ラインがバック取りした場合の成績と所属ラインがバック取りをしなかった場合の成績を使用した。直近 1095 日の成績については、直近 1095 日に出場した全レースの成績に加えて、対象競輪場におけるレースの成績を使用した。

また、対象競輪場における成績については、ラスト半周における速度の平均値と最大値を成績として使用した。直近3レースの成績として、レースで獲得した競争得点、順位、バック取りの有無を使用した。直近10レースの成績として、連続で n 着以内に入賞した回数 ($n = 1, 2, 3$) を使用した

関係性特徴 x^r では、同じラインの選手と前方選手、後方選手を使用した。例えば、ラインが1-9-3の場合、車番9における同じラインの選手は $[1, 0, 1, 0, 0, 0, 0, 0, 1]$ 、前方選手は $[1, 0, 0, 0, 0, 0, 0, 0, 0]$ 、後方選手は $[0, 0, 1, 0, 0, 0, 0, 0, 0]$ というベクトルで表現する。

また、バイナリで表される特徴以外は最大値1、最小値0の範囲で正規化した。

評価指標 予測器の予測精度を二車単 y_1, y_2 、三連単 y_1, y_2, y_3 、展開を含んだ二車単 y_0, y_1, y_2 の正解率で評価した。正解率については、予測器を使用して全ての車番の組み合わせについてレース結果の生起確率を推定し、上位 K 件に実際のレース結果が含まれる割合 (Top-K accuracy) を計算した。

1レースの予測にかかる時間によって予測器の処理速度を評価した。処理速度の計測は16GBのRAMを備えたCPU環境 (Intel(R) Core(TM) i7-9700 CPU @ 3.00GHz) の計算機を用いて100回の推論を行い、その実行時間によって評価した。

予測器の出力に基づいて選択された配当の期待値が高い車券によって、車券の購入金額を上回る配当を得ることが可能であるかについて回収率で評価した。予測器により推定される着順の生起確率と対応する車券のオッズの積によって配当の期待値を計算する。全ての二車単の車券に対して配当の期待値を計算し、期待値が閾値以上となる車券を全て100円ずつ購入した時に、実際のレース結果に従って配当される金額を計算する。配当の期待値の計算には確定オッズを使用し、配当金額の計算では、予測器の出力に基づいて車券を購入した際に発生するオッズの変動を無視することとした。実際の投票券購入の際には確定オッズを使用することはできないが、過去に実施されたレースについて投票締切前までのオッズのデータを取得することが困難であったため、確定オッズを使用した。投票締切前のオッズの変動などを考慮した評価は今後の課題である。ここで、回収率は配当金額を購入金額で除算した値である。

比較するモデル 前述のTransformerによるモデルの他に、多層パーセプトロン (MLP) によるモデルと確定オッズの3つのモデルを用いた予測器を比較する。

MLPは系列 y の予測を単純な多クラス分類として扱うモデルである。分類クラス数は4,536 ($9 \times 9 \times 8 \times 7$) である。MLPの構造の概略図を図3.3に示す。MLPの中間層の層数は $N_{MLP} = 2$ 、各層の次元は $d_{mlp} = [1024, 512]$ とした。MLPの

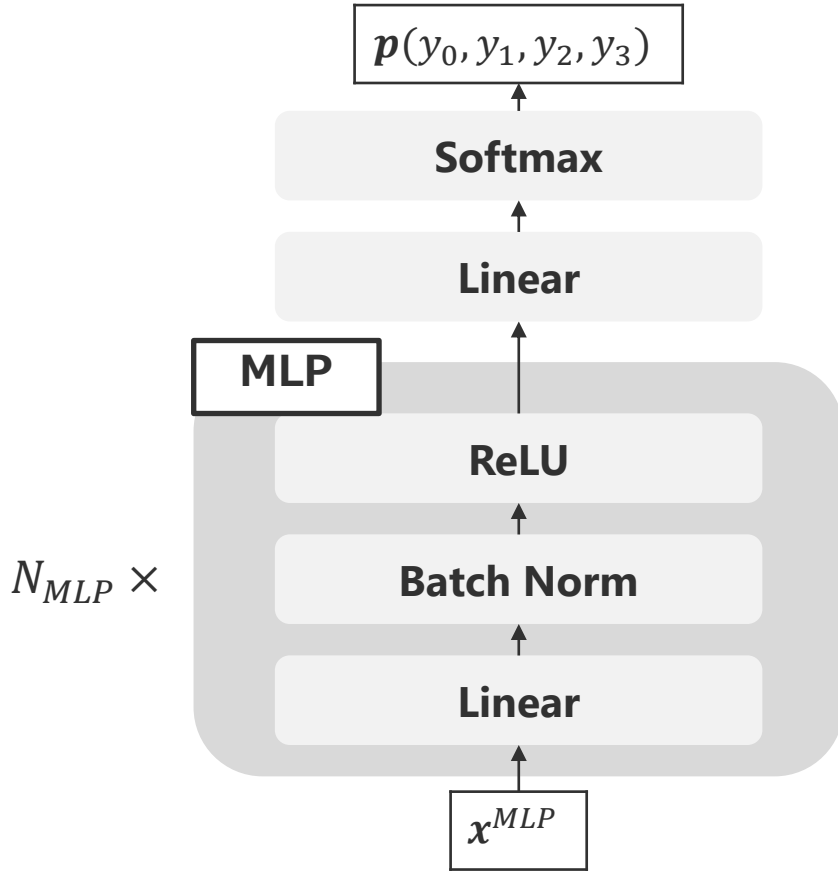


図 3.3: MLP による予測器の概略図

入力には式 3.13 に示すように、各特徴を全て結合したベクトル \mathbf{x}^{MLP} を使用した。

$$\begin{aligned}\mathbf{x}^{MLP} &= (\mathbf{x}^c, \mathbf{x}^p, \mathbf{x}^r) & (3.13) \\ \mathbf{x}^p &= (\mathbf{x}_1^p, \mathbf{x}_2^p, \dots, \mathbf{x}_9^p) \\ \mathbf{x}^r &= (\mathbf{x}_{1,2}^r, \mathbf{x}_{1,3}^r, \dots, \mathbf{x}_{9,8}^r)\end{aligned}$$

バッチサイズ、学習率の初期値、Optimizer については、Transformer と同じ設定を使用した。損失関数は式 3.14 に示すクロスエントロピーを使用した。

$$L = -\log p(t_0, t_1, t_2, t_3) \quad (3.14)$$

ハイパーパラメータの探索範囲を表 3.11 に示す。ハイパーパラメータの探索はグリッドサーチによって行い、検証データに対する誤差の最も小さいハイパーパラメータを採用した。

確定オッズは、投票締切後の確定されたオッズである。競馬ではオッズの馬の勝利確率の推定精度が非常に高いという報告 [62] があり、オッズは優れた予測器であるともいえる。そのため、予測の正解率の比較に確定オッズを使用した。

表 3.11: ハイパーパラメータの探索範囲

共通	lr_{init}	0.01, 0.001, 0.0001
Transformer	N_e	2, 4, 6
	N_d	2, 4, 6
	d_f	128, 256
	h	1, 2, 4
MLP	d_{mlp}	$[2^n](n = 8, 9, 10, 11),$ $[2^n, 2^{n-1}](n = 8, 9, 10, 11),$ $[2^n, 2^{n-1}, 2^{n-2}](n = 9, 10, 11),$

表 3.12: 二車単 y_1, y_2 , 三連単 y_1, y_2, y_3 , 展開を含んだ二車単 y_0, y_1, y_2 の Top-K Accuracy

	二車単	二車単	二車単	三連単	三連単	三連単	二車単	二車単	二車単
	y_1, y_2	y_1, y_2	y_1, y_2	y_1, y_2, y_3	y_1, y_2, y_3	y_1, y_2, y_3	y_0, y_1, y_2	y_0, y_1, y_2	y_0, y_1, y_2
	@1 [%]	@2 [%]	@10 [%]	@1 [%]	@2 [%]	@10 [%]	@1 [%]	@2 [%]	@10 [%]
MLP	22.21	35.11	71.56	9.83	16.28	39.92	16.32	26.05	53.77
Transformer	22.89	36.31	73.18	10.44	17.27	41.14	16.95	27.31	56.40
確定オッズ	22.83	36.30	72.80	10.01	16.61	40.90	-	-	-

正解率について Transformer, MLP, 確定オッズを比較し, 処理速度について Transformer と MLP を比較した. 回収率については Transformer を評価した.

結果・考察

各モデルのバック取り選手, 1着選手, 二車単, 三連単の Top-K accuracy を表 3.12 に示す. 確定オッズについてはバック取り選手の予測ができないため, 該当するセルは記載なしとしている. Transformer による予測器は, 全ての項目において確定オッズよりも精度が高く, テキスト情報の生成のための十分な精度を達成できていることを示している.

表 3.13 は各モデルの 1 レースの予測にかかった時間を示しており, Transformer による予測器は予測にかかる時間が MLP と比較して大きい. これは, MLP による予測器は 1 回の推論でバック取り, 1着, 2着, 3着の同時確率 $\mathbf{p}(y_0, y_1, y_2, y_3)$ を全ての組み合わせに対し出力できることにに対し, Transformer による予測器は全パターンの条件付き確率を出力するために $648(9 \times 9 \times 8)$ 回の推論が必要になることが原因である. 1つの競輪場におけるレースの開始時間の間隔が 20 分 (1200 秒) 程度は空いている点から, Transformer による予測器の実行時間はシステムの運用上問題にはならないといえる. また, 本稿では Transformer による予測器を用いる

表 3.13: 1 レースの予測にかかる時間 [秒] (100 試行)

	平均値	標準偏差
MLP	0.2	0.0
Transformer	454.6	3.0

表 3.14: Transformer による予測器の回収率

閾値	購入レース数	正解レース数	正解率 [%]	購入金額 [円]	配当金額 [円]	収支 [円]	回収率 [%]
1.0	19,666	5,625	28.6	21,776,100	23,499,850	1,723,750	107.9
1.5	15,977	1,407	8.8	6,888,200	9,791,173	2,902,973	142.1
2.0	9,395	450	4.8	2,484,600	4,821,941	2,337,341	194.1
2.5	4,921	164	3.3	1,020,800	2,433,636	1,412,836	238.4
3.0	2,659	76	2.9	489,900	1,738,244	1,248,344	354.8

際に全ての着順の組み合わせについて生起確率を計算しているが、さらに長い系列の予測が求められる場合でもビームサーチなどの手法を用いて予測器の実行時間を削減することが可能である。

回収率の計算結果を表 3.14 に示す。本実験設定において、確定オッズが最小の車券を 1 点購入した場合の回収率は 77.5% であり、確定オッズに従って車券を選択しても、購入金額を上回る配当を得ることはできない。一方で、予測器は購入金額に対する配当金額の割合の期待値が 1.0 以上となる車券を選択することで、確定オッズに従う選択よりも優れた 100% を超える回収率を達成可能であることを示している。以上の結果は、本予測器が確定オッズと着順の生起確率との乖離を発見し、回収率の面でもテキスト情報の生成のための十分な精度が達成できていることを示している。

3.4 まとめ

本章では、テキスト情報の生成の元となるデータの生成についての研究として、競輪のレース展開の予測を行った。レース展開として最終半周時点で先頭の選手、1 着の選手、2 着の選手、3 着の選手を予測した。

競輪のレース展開を高い精度で予測するためには、競輪特有のラインというチーム関係によって生じる選手間の相互作用を考慮することが重要であると考えられる。先行研究である競馬予測では選手 1 人を入力としてその選手の強さを推定するというモデルに関する文献が多い。一方で、競輪ではラインを考慮するために複数人の選手を入力とするモデルが有効であることが想定される。そこで本章では入力と出力が異なる 3 つのニューラルネットワーク (MLP) を比較し、選手 9 人を入

力としてレース展開が生起する確率を出力するモデルが最も高い精度でレース展開を予測できることを示した。さらに、近年様々なドメインで高い性能を示しているニューラルネットワークの一つである Transformer を使用し、学習データ量の増加や入力特徴量の改良加えた結果、精度が高いと知られている確定オッズよりも高い予測精度を達成した。また、Transformer の出力する投票券の的中確率と確定オッズの積によって計算される配当金の期待値に基づいて購入する投票券を選択することで、100%を超える回収率を達成した。回収率による評価は実際の意思決定時点では使用することができない確定オッズを使用しているという点には注意が必要であり、投票締切前のオッズの変動などを考慮した回収率の評価は今後の課題である。これらの結果から、競輪の投票券購入をするユーザにとって有用なテキスト情報を生成するための元となるレース展開の予測が達成されたといえる。

第4章

テキスト情報の生成

4.1 はじめに

本章では、第3章で生成したレース展開の予測情報から、ユーザにとって有用なテキスト情報を生成する。公営競技において多くのユーザが共通して考慮すると考えられる要素である配当金の獲得・レース展開の予測に有用なテキスト情報を生成する。

テキスト情報の生成の手法として代表的なものにテンプレートを用いる手法とニューラル言語モデルを用いる手法が挙げられる。テンプレートを用いる手法は事前に人手で設定したテンプレートに値を当てはめる手法であり、テンプレートやその使用ルールを設計する作業が必要となるが、生成テキストの文法的な正確さや事実に対する正確さが保証されるという利点がある。ニューラル言語モデルによる手法は、学習用のデータがある場合は流暢な高品質なテキストが生成可能である [34, 35]。一方で生成の制御が難しく、事実と異なるテキストを生成する場面も存在するという問題 [36, 37, 38] なども報告されている。またさらに近年では、PaLM[40] や GPT-4[41] といったより大規模な言語モデルでは、追加の学習をすることなく流暢で高品質なテキストが生成可能である。本章ではテンプレートを用いた手法により、ユーザにとって有用なテキスト情報を生成する。本章のテキスト情報の生成のプロセスの概要を 4.1 に示す。第3章で生成したレース展開の予測情報に加えて、それに関連するレースや選手、オッズなどの情報を付加したテキスト情報をテンプレートによって生成する。また、既存のテキスト情報を学習データに使用してニューラル言語モデルの一つである GPT-2 を fine-tune することでテキスト情報を生成する手法についても検討する。

ユーザの意思決定において有用なテキスト情報を生成するための手法として、ユーザによる情報の有用性についての評価のフィードバックデータを使用する手法と使用しない手法の2種類の手法が考えられる。フィードバックデータを使用する

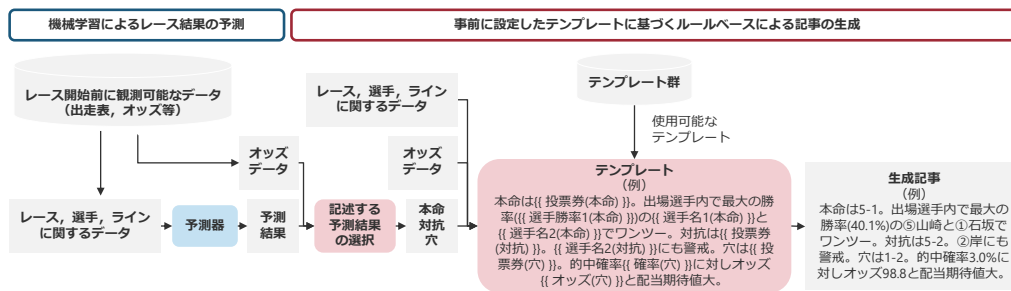


図 4.1: テンプレートを用いたテキスト情報の生成の概要

手法の例として、フィードバックデータを学習データとして分類器を学習し、その分類器の出力に基づいて強化学習によりニューラル言語モデルを学習させる手法などが挙げられる。先行研究として、広告文生成において広告文から CTR を予測する予測器を学習し、その予測器の出力を報酬とした強化学習により LSTM によるテキスト生成器を学習させる研究 [72] などがある。一方で、現実の意思決定問題の多くはこうしたフィードバックデータが蓄積されていない場合が多い。そのため、本論文ではユーザによる情報の有用性についての評価のフィードバックデータを使用せず、既存のテキスト情報の分析や意思決定問題の特徴などから有用な情報を検討し、人手によって設定したテンプレートによってテキスト情報を生成する手法を採用する。本手法は、対象とする意思決定問題ごとに人手による作業が必要になるが、その他の多くの現実の意思決定問題に対して適用可能な手法である。

本章では、4.2 節でテンプレートを用いた手法の有効性について検討するために、実際にテンプレートを作成してテキスト情報を生成した研究成果について示す。4.3 節では、Web サイトで配信される既存のテキスト情報を対象とした分析および意思決定の特徴に基づいて、テンプレートを用いた手法により有用なテキスト情報を生成し、生成したテキスト情報についてドメインエキスパートによる評価実験を実施した研究成果について示す。4.4 節では、既存のテキスト情報を学習データに使用して fine-tune した GPT-2 によってテキスト情報を生成した研究成果について示す。4.5 節では、本章のまとめを示す。

4.2 テンプレートを用いた生成手法の検討

本節では、テンプレートを用いた手法の有効性を検討するために、簡単なテンプレートを実際に設定し生成されるテキスト情報の例を確認する。

4.2.1 競輪におけるテキスト情報

本節では、現在人手によって作成されているテキスト情報にどのような情報が含まれているかを検証する。

既存のテキスト情報

競輪では実施される全レースに対して人手によってテキスト情報が作成され、新聞や投票サイトでユーザに向けて配信されている。投票サイトで配信されている既存のテキスト情報の例を以下に示す。既存のテキスト情報はオッズパーク [73] より引用した。

- 既存のテキスト情報の例 1
 - － 磯島が駆けて番手の野木が本命。鋭さ光るのは丸山だ。逆転の捲りに一考。目標の高鍋次第で大久保，攻め多彩な吉田も怖い。
- 既存のテキスト情報の例 2
 - － 持ち前のスピードを全開なら⑤松本―②蓮井でワンツー。自在③田中―⑨米原の捲りや同県⑥山田にマークする④竹内や⑦内村も単級
- 既存のテキスト情報の例 3
 - － 藤縄―中澤の近畿勢に期待。隅田―高津，中部勢の抵抗も見ものだろう。
- 既存のテキスト情報の例 4
 - － 函館最終戦のオープニングレースは2分の争いとなった。ラインの先頭を走る自力型の先行力は、ほぼ互角とみるが109期のルーキー神山が主導権を握ると見て番手を回る①田中が鋭く追い込む。ラインの⑤松本が続き本線を形成。対し大阪勢も侮れない。ライン4車の利を活かし④斎藤が巧く駆けると番手を回る②陶器とのワンツーも狙える。

以上から、既存のテキスト情報が含む情報として次の4つが挙げられる。

- 上位予想選手
- 上位予想選手に関する情報
- ラインに関する情報
- レース展開に関する情報

上記4つの情報が具体的にどのような情報なのかを、既存のテキスト情報の例1を例に説明する。上位予想選手は、記事の筆者が上位に入る可能性が高いと予想する選手であり、既存のテキスト情報の例1では「野木」、「丸山」、「大久保」、「吉田」である。上位予想選手に関する情報は、なぜその選手が上位に入ると予想されたかを説明する情報であり、既存のテキスト情報の例1では「鋭さ光る」、「攻め多彩な」である。ラインに関する情報は、ラインによって生じるレース結果についての情報であり、既存のテキスト情報の例1では「磯島が駆けて番手の」、「目標の高鍋次第で」である。レース展開に関する情報は、レースの途中経過を表し、既存のテキスト情報の例1では「逆転の捲りに一考」である。

既存のテキスト情報の例3は上位予想選手に関する情報とレース展開に関する情報を含んでいない。このように、必ずしも4つ全ての情報が既存のテキスト情報に含まれているというわけではない。

本節では上記4つの情報の内、レース展開に関する情報を除いた上位予想選手、上位予想選手に関する情報、ラインに関する情報を含むテキスト情報を生成することを目的とする。

4.2.2 テキスト情報の生成手法

本節では、テンプレートによってテキスト情報を生成する手法について示す。本節では、予測結果、選手データ、ラインデータに基づいて、事前に用意したテンプレート群から使用するテンプレートを選択し、そのテンプレートに選手名などの情報を当てはめることでテキスト情報を生成する。本節では、選手名と順位を説明するだけの単純な文をもとに、テンプレートを作成した。以降では、4.2.1節で設定した次の3つの情報を含むテンプレートを作成する手法と、生成時にどのようにテンプレートを選択するかを説明する。

- 上位予想選手
- 上位予想選手に関する情報
- ラインに関する情報

テンプレートの作成

次の基本文をもとにテンプレートを作成する。

- <選手名> が <順位> 着。

テンプレートは次のように基本文を3つ繋げることで作成する。

- <1着選手名>が1着. <2着選手名>が2着. <3着選手名>が3着.

この文に予測結果を当てはめることで、上位予想選手についてのテキスト情報を生成可能である、さらに、基本文の先頭、<順位>の前(中間)、末尾に選手情報のテンプレートとライン情報のテンプレートを挿入することで、上位予想選手に関する情報とラインに関する情報を含むテンプレートを作成する。つまり、選手情報のテンプレートとライン情報のテンプレートについて使用条件と挿入可能位置を設定することでテンプレートを作成する。

選手情報のテンプレート 選手情報のテンプレートとはどのようなものかを示す。実際に設定した選手情報のテンプレートの例を以下に示す。

- 直近4ヶ月の勝率<1着選手勝率>%の
 - 挿入可能位置：1着，先頭
 - 使用条件：1着選手の過去4ヶ月の勝率 $\geq 20\%$

この選手情報手のテンプレートは、1着選手の基本文の先頭に挿入可能で、1着選手の過去4ヶ月の勝率が20%以上の場合に使用可能である。本稿では簡単のため選手情報のテンプレートの挿入可能位置を1着選手の基本文の先頭に限定した。このように、選手データを使用条件に用い、その条件に応じた出力をするテンプレートを設定することで、上位選手に関する情報を含むテンプレートを作成する。

ライン情報のテンプレート ライン情報のテンプレートとはどのようなものかを示す。実際に設定したライン情報のテンプレートの例を以下に示す。

- でワンツーフィニッシュ
 - 挿入可能位置：2着，末尾
 - 使用条件：1着選手と2着選手が同じライン

このライン情報のテンプレートは、2着選手の基本文の末尾に挿入可能で、1着選手と2着選手が同じラインの場合に使用可能である。このように、ラインデータを使用条件に用い、その条件に応じた出力をするテンプレートを設定することで、ラインに関する情報を含むテンプレートを作成する。

テキスト情報の生成

本節では実際のテキスト情報の生成手順について説明する。

テキスト情報を生成するときは、テンプレート群から予測結果、選手データ、ラインデータに基づいて使用条件を満たしているテンプレートを選択する。テンプレートの使用条件は、そのテンプレート内の選手情報のテンプレートとライン情報のテンプレートの使用条件の論理積で表される。つまり、テンプレート内の全ての選手情報とライン情報のテンプレートの使用条件を満たしている場合にそのテンプレートは使用可能となる。そして、選択したテンプレートに選手の名前や勝率などのデータを当てはめることでテキスト情報を生成する。

4.2.3 テキスト情報の生成結果・考察

2016年のレースに対し実際に生成したテキスト情報の例と既存のテキスト情報を表4.1, 表4.2, 表4.3, 表4.4に示す。既存のテキスト情報はオッズパーク [73] より引用した。

既存のテキスト情報と比較すると、生成したテキスト情報は既存のテキスト情報と同じ選手を上位予想選手としていることが多く確認できる。表4.1の例では、生成したテキスト情報に記載されている武藤、太田、江口の3人が既存のテキスト情報にも上位予想選手として記載されている。これは、既存のテキスト情報を作成した専門家に近い予測ができていていることを示している。

生成したテキスト情報の例から上位予想選手に関する情報を含むテキスト情報を生成できていることが確認できる。表4.2の例では、1着予測選手（蓮井）の過去4ヶ月の勝率が22.7%であるという記述がされている。本稿で設定した条件によって、2016年レースの71.7%に上位予想選手に関する情報を含むテキスト情報が生成された。

生成したテキスト情報の例からライン構成を説明するテキスト情報が生成できていることが確認できる。表4.2の例は、1着予測の選手（蓮井）と2着予測の選手（越智）が同じラインに所属していることを説明している。同様に表4.1の例は、1着から3着予測の選手（村本、小林、清水）が全員同じラインに所属していることを説明している。また、表4.3の例では、1着から3着予測の選手（武藤、太田、江口）が全員異なるラインに所属していることを説明している。

本節で設定したライン情報のテンプレートの組み合わせによるテンプレートの総パターン数は438である。選手情報のテンプレートとの組み合わせも合わせると約4,000になり、競輪の1日のレース数が60ということから十分な数のパターン数であると考えられる。しかし、もととなっている基本文が1つということや、同じような単語・フレーズの使い回しにより、既存のテキスト情報と比較すると語彙や文のパターンが乏しいということが課題である。

表 4.1: 生成したテキスト情報と既存のテキスト情報の例 1

2016-1-20 佐世保競輪場 第 6 レース	
既存のテキスト情報	混戦だが②武藤の自力に期待. ③米嶋⑨江口が逆転狙い. ⑧砂川も②武藤マークから連入も. 穴は⑦高谷の自在戦から. ①太田のコース注意.
生成したテキスト情報	勝ち星を量産している②武藤が自力で 1 着. 別線から①太田が 2 着とスジ違いの決着. 九州ラインから⑨江口が 3 着と, 各ラインから上位者が出ると予測.

表 4.2: 生成したテキスト情報と既存のテキスト情報の例 2

2016-5-27 佐世保競輪場 第 6 レース	
既存のテキスト情報	捲りタイプの⑤越智だが前々から自力で首位期待. ②蓮井の逆転も. ⑦佐伯も同県③渡邊マークから 7 = 3 狙いは十分. ここは押さえない.
生成したテキスト情報	直近 4 ヶ月勝率 22.7%の②蓮井が⑤越智の自力から差して 1 着. 同ラインの⑤越智が②蓮井に続いて 2 着でワンツーフィニッシュ. ④桜井が 3 着.

生成したテキスト情報を車券販売サービス会社の関係者に確認してもらった結果, 高評価を受け, 本システムは Web ページ上で実用化されている. これは, 生成したテキスト情報が実用レベルの質を確保していることを示している. また, 本研究の成果は競輪業界の抱えるコンテンツ自動生成技術への需要といった課題の解決に貢献していることを示している.

本節で提案したレース展開予測を含むテキスト情報の生成システムは実用化されており, 株式会社チャリ・ロトの Web ページ AI-win¹にて生成したテキスト情報を投票締切 10 分前に公開している. また, その過程で得られる各車券の推定的中確率と公開情報であるオッズを用いて, 配当金を考慮した購入車券の提案もテキスト情報と同じく公開している.

4.3 テンプレートを用いた生成手法によるテキスト情報の生成と評価

本節では, ユーザにとって有用なテキスト情報を生成するために, 既存のテキスト情報を対象とした分析と意思決定問題の特徴からテキスト情報に含める情報を検

¹<https://ai.chariloto.com/>

表 4.3: 生成したテキスト情報と既存のテキスト情報の例 3

2016-10-22 青森競輪場 第 3 レース	
既存のテキスト情報	△村本に期待 村本が自力含みで臨機応変に攻める。小林は村本に付けて好位差し。南関のワンツー本命。武笠も狙いたい一車。小塚が駆ければ首位浮上。好配は線違い。
生成したテキスト情報	ここ 4 ヶ月勝率 44.8%の④村本が自力を生かして 1 着。同ラインの①小林が④村本に続いて 2 着。⑦清水が 3 着。南関ラインが別線を抑えて上位独占と予測。

表 4.4: 生成したテキスト情報と既存のテキスト情報の例 4

2016-7-13 岐阜競輪場 第 1 レース	
既存のテキスト情報	互角の争いも①伊藤に期待。好機に仕掛けて押し切ろう。南関勢⑨松江が喰い下がる。新鋭⑥竹元が果敢に主導権を握ると、③川島のガードで逃げ切りも十分。
生成したテキスト情報	若手の⑥竹元が自力を生かして 1 着。番手から③川島が⑥竹元に続いて 2 着。⑧西島が 3 着。

討する。4.2 節と同様のテンプレートを用いた手法によってテキスト情報を生成し、ドメインエキスパートによる評価実験によってその有効性を検証する。

4.3.1 競輪におけるテキスト情報

本節では、競輪のプロスポーツ競技としての概要と公営競技としての概要を示す。次に、既存のテキスト情報がどのような文章であるかについて定性的および定量的に分析し、本節で生成するテキスト情報の目標を示す。

意思決定問題の特徴

本節では、競輪の競技としての概要と公営競技としての概要といった意思決定問題の特徴から、ユーザにとって有用な情報について考察する。

競技概要 競輪は、自転車を使用したトラックレースである。レースは最大 9 人で行い、バンクと呼ばれる競争路を周回し 1,500m から 3,000m の距離を走破する順番を競う。

競輪にはその他のトラックレースには無いラインという要素がある。選手はレース中にラインと呼ばれる縦列を形成し、同じラインの選手同士で協力しながらレースを進める。出場選手は誰の後ろにつくのか、自分が先頭で走るか否かについてレース開始前に宣言するため、どの選手同士がラインを組むかはレース開始前に公開される情報である。多くの場合は、同じ地域に所属する選手同士でラインを組む。ラインの先頭を走る選手（先行選手）には、走る速度や加速のタイミングを自由に決定可能というメリットがあり、先行選手の後ろを走る選手（番手選手）には、前方の選手を風よけとして使用し体力を温存可能というメリットがある。最後のゴール前の直線まで選手は同一ラインの選手と協力して走るが、レースの賞金は個人に与えられるため、最後は同一ラインの選手とも競争し、各個人が1着を目指す。

ラインによって生まれるレース展開は、競輪のレース結果を予想する際に考慮すべき要素の一つである。そのため、観客の車券購入の意思決定補助および記事の面白さのために、ラインに関する情報とレース展開をテキスト情報に記述する必要がある。また、選手の過去成績といった選手に関する情報もレース結果を予想する際に考慮すべき要素であり、テキスト情報に記述する必要がある。

公営競技概要 公営競技は、公的機関が賭博として開催するスポーツである。競輪などの公営競技の開催によって得られた収益金の一部は、地方自治体の行う学校、病院、道路などの公共施設の整備費に当てられている。そのため、車券の購入を促進することによって、開催者の利益だけでなく、社会的な利益への貢献が期待される。

観客はレース結果を予想した投票券（車券）を購入して、予想が正解した場合、配当を受け取る。競輪の車券は、パリミュチュエル方式によって販売されており、配当の倍率（オッズ）は観客全体の投票割合によって決定される。競輪の賭式は全部で7種類あり、代表的なものに、1着と2着の車番を着順通りに予想する賭式（二車単）、1着から3着の車番を着順通りに予想する賭式（三連単）がある。ここで、車番はレースごとに選手に与えられる番号である。オッズは観客全体の得票割合から決定されるため、観客が車券の購入金額を上回る配当を得るためには、投票券の生起確率を推定し、推定した値とオッズとの乖離を見つけることが重要である[62]。

観客の多くは、車券の購入金額より多くの配当を獲得したいと考えていると想定される。そのため、観客の車券購入の意思決定補助および記事の面白さのためには、テキスト情報に配当の期待値が高い車券について記述する必要があると考えられる。

表 4.5: 既存のテキスト情報の例

例 1	藤縄一中津の近畿勢に期待。隅田一高津，中部勢の抵抗も見ものだろう。
例 2	磯島が駆けて番手の野木が本命。鋭さ光るのは丸山だ。逆転の捲りに一考。目標の高鍋次第で大久保，攻め多彩な吉田も怖い。
例 3	持ち前のスピードを全開なら⑤松本一②蓮井でワンツー。自在③田中一⑨米原の捲りや同県⑥山田にマークする④竹内や⑦内村も単級。
例 4	函館最終戦のオープニングレースは2分の争いとなった。ラインの先頭を走る自力型の先行力は、ほぼ互角とみるが109期のルーキー神山が主導権を握ると見て番手を回る①田中が鋭く追い込む。ラインの⑤松本が続き本線を形成。対し大阪勢も侮れない。ライン4車の利を活かし④斎藤が巧く駆けると番手を回る②陶器とのワンツーも狙える。
例 5	好調維持する三浦が，積極策でレースを支配。坂口が番手の仕事をして東北ワンツー決める。地元岡崎の差し脚も侮れない。目標の武藤が突張り，カマシで前に出切れれば直線抜け出し逆転も狙える。

定性的分析

本節では既存のテキスト情報の例から，その記述内容について考察する。既存のテキスト情報として投票サイトで配信されているテキスト情報を対象とし，チャリロト [74] およびオッズパーク [73] から引用した。既存のテキスト情報の例を表 4.5 に示す。既存のテキスト情報は開催競輪場によって著者が異なるため，著者ごとにテキスト情報の傾向は異なるが，多くのテキスト情報に共通する点として二車単ベースの予想，複数予想の記述，レース展開・ライン・選手に関する情報の記述が挙げられる。

二車単ベースの予想 既存のテキスト情報には，一着選手および二着選手の予想の組を記述した二車単ベースの予想が多く見られた。例 1 では「藤縄一中津」，「隅田一高津」，例 3 では「⑤松本一②蓮井」，「③田中一⑨米原」というように着順が上位になると予想された 2 人の選手の名前が記述されている。これは，競輪の賭式として，1 着の選手のみを予想する車券は存在せず，観客は少なくとも 2 着以内に入賞する選手の組合せを予想する必要があるためである。そのため，既存のテキスト情報では二車単をベースとした予想の記述が多いと考えられる。

複数予想の記述 既存のテキスト情報例から，どのテキスト情報も複数の予想を記述していることが確認できる。例 1 では，「藤縄一中津」と「隅田一高津」の 2 つの

予想が記述されている。レース結果の予測は不確実な要素が多く関係するタスクであるため、高い精度で予測することは難しい。例えば、二車単で最も多く購入された車券通りの着順が実際に生起する確率は22.8%程度である。そのため、観客は複数の車券に賭金を分散させることも多く、テキスト情報中で複数の予想を記述することは観客の車券購入の意思決定補助に有効であると考えられる。

レース展開・ライン・選手に関する情報の記述 レース展開として、例2では「逆転の捲りに一考.」、例3では「③田中―⑩米原の捲り」というように、レース終盤に後方から一気に先頭に抜き出てゴールする（捲り）というレース展開が記述されている。ラインに関する情報として、例5では「坂口が番手の仕事をして東北ワントゥー決める.」というように、東北地域に所属する選手で構成されるラインが上位になるという情報が記述されている。また例2では「番手の野木が本命」というように、上位になると予想する選手のラインでの位置に関する情報が記述されている。選手に関する情報として、例2では「攻め多彩な吉田」、例5では「好調維持する三浦」が記述されている。

意思決定問題の特徴に基づく考察でテキスト情報に必要な要素として挙げたレース展開、ライン、選手に関する情報が既存のテキスト情報にも記述されていることが確認できる。

定量的分析

本節では、既存のテキスト情報についてテキスト情報中での言及選手数、頻出単語について注目し、既存のテキスト情報がどのような文章であるか考察する。2014年1月から2019年6月の期間にオッズパーク [73] にて配信された、123,559件の既存のテキスト情報を分析対象とする。

言及選手数 既存のテキスト情報におけるテキスト全体での言及選手数の頻度分布を図4.2に示す。既存のテキスト情報全体におけるテキスト内での言及選手数の平均値は3.99であり、中央値は4であった。販売される競輪の車券は全て、3着までの選手の組み合わせを予想するものであり、4着の選手を予想する意味は薄い。そのため、既存のテキスト情報では複数の予想が記述されていると考えられる。

頻出単語 形態素解析にMeCab[75]を使用し、辞書としてmecab-ipadic-neologd [76]を使用して既存のテキスト情報に出現する頻出単語を分析する。名詞と動詞の頻出単語上位5つを表4.6に示す。名詞に関しては、マーク、番手、自力、先行といったラインに関する単語が出現数の上位を占めており、既存のテキスト情報にライン

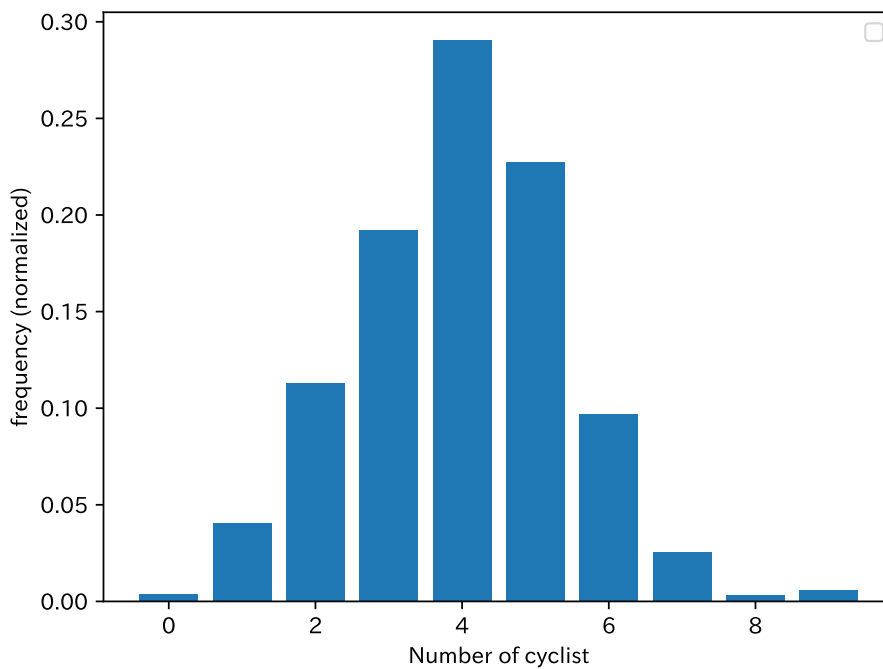


図 4.2: 記事内での言及選手数の頻度分布

表 4.6: 頻出単語

名詞	出現数	動詞	出現数
マーク	27,831	する	63,911
番手	25,480	捲る	36,361
自力	23,702	ある	22,437
先行	21,234	いる	11,277
期待	17,279	てる	10,965

に関する情報が含まれていることを示している。動詞に関しては、捲るというレース展開に関する単語の出現数が高く、既存のテキスト情報にレース展開の情報が含まれていることを示している。

目標とする記事

以上より、本節で生成するテキスト情報の目標を以下の通り設定する。

- 二車単ベースの予想の記述
- 複数の予想の記述
- 配当の期待値が高い車券の記述

- レース展開の記述
- ラインに関する情報の記述
- 選手に関する情報の記述

本稿では、上記の条件を満たすテキスト情報を生成するために、二車単の車券にかかわる1, 2着の選手の組み合わせとレース展開を予測し、予測情報に基づいてテキスト情報を生成する。

4.3.2 生成手法

本節では、図4.1に示す通り、テンプレートを使用するルールベース手法によってテキスト情報を生成する。テンプレートにデータを当てはめて文章を生成する仕組みは、4.2節と同じである。本節では、記述する予測結果の選択方法と設定したテンプレートについて示す。

記述する予測結果の選択

第3章で開発した予測器の推定した着順の生起確率に基づいて、記述する予測結果を選択する。一般的な公営競技における着順予想は、本命や対抗、単穴、連下、穴といった、いくつかの種類に分類される。本節では、最も生起確率の高い車券を本命、二番目に生起確率の高い車券を対抗として選択し、複数の予想が記述された記事を生成する。また、配当の期待値が1.0以上かつ生起確率が0.001以上となる車券のうち、期待値が最大の車券を穴として選択することで、配当の期待値が高い車券についての記述を生成するテキスト情報に盛り込む。配当が購入金額を上回るという点の他に、購入車券が当たるという点も重要であると考えられるため、配当の期待値の条件に加えて生起確率0.001以上という条件を指定した。二車単ベースの予想を記述するために、記述する予測結果として選択する車券は二車単を対象とした。

テンプレート

本命、対抗、穴のそれぞれの予測結果を説明するようなテンプレートを設定し、3つのテンプレートを組み合わせることで、1つのテキスト情報のテンプレートとする。図4.1に示すように、テンプレートにはスロットが用意されており、スロットに選手名や選手の過去成績といった対応する値を代入することでテキスト情報を生成する。本稿では、ある条件下で使用可能なテンプレートが複数存在する場合には、ランダムに1つ選択する。本稿で設定したテンプレートの類型化したスロット

を表 4.7 に示す。テキスト情報のテンプレートの総パターン数は 360 である。競輪の 1 日のレース数が約 50 レースであることから、十分なパターン数であると考えられる。本命、対抗、穴の各テンプレートにはそれぞれ異なる軸に基づいて使用条件が設定されており、条件に合った文章が生成される。設定した使用条件の軸を表 4.8 に示す。本命、対抗、穴の各テンプレートについては、4.3.1 節で示したライン、選手、レース展開に関する情報を記述するテンプレートを設定した。

ラインに関する情報の記述 表 4.8 に示したように、本命テンプレートにはラインに関する使用条件を設定した。条件に応じた所属ラインや所属ラインでの位置（先行、番手）に関する情報をテンプレート化することで、テキスト情報にラインに関する情報を記述する。

選手に関する情報の記述 本稿では、既存のテキスト情報で記述されているような「攻め多彩な」といった定性的な情報の代わりに、「競争得点 90.8 の」のように選手の過去成績といった定量的な情報をテンプレート化した。選手に関する情報のテンプレートは、選手名の前に挿入することでテキスト情報に選手の情報を記述する。本稿で報告するテンプレートのパターン数は、選手に関する情報のテンプレートの違いを考慮していない。表 4.7 の選手の過去成績に関するスロット（ $\{\{ \text{過去成績} \}\}$ ）として、Web 上の出走表で公開される過去 4 ヶ月の 1 着数や勝率、競争得点、決まり手数などの情報を使用した。選手の秀でていない成績の記述を避けるために、過去成績に関するスロットは代入する値は 0 ではなく、かつレース内の平均値以上の値である場合に使用可能とした。

レース展開の記述 表 4.8 に示したように、本命テンプレートにはレース展開に関する使用条件を設定した。予測器の出力から、ラスト半周の時点で 1 位（バック取り）だったラインがそのまま逃げ切ってゴールするのか、ラスト半周の時点では 1 位ではないラインがラスト半周から捲って 1 位になりゴールするのかを記述するテンプレートを設定した。予測器の出力が以下の条件を満たす場合にレース展開を記述するように設定した。

- バック取り確率が最も高い選手がバック取りした場合に最も生起確率が高い二車単 $\text{argmax}_{y_1, y_2} [\mathbf{p}(y_1, y_2 | y_0 = \text{argmax}(p(y_0)))]$ と最も生起確率が高い二車単 $\text{argmax}_{y_1, y_2} [\mathbf{p}(y_1, y_2)]$ が同じであること。
- 最も生起確率が高い二車単 $\text{argmax}_{y_1, y_2} [\mathbf{p}(y_1, y_2)]$ において、車番 y_1 と車番 y_2 が同じラインであること。

表 4.7: 類型化したテンプレートのスロット

スロット	代入する値の例
{{ 投票券 }}	1-2
{{ 確率 }}	10.4%
{{ オッズ }}	50.3
{{ ライン名 }}	中国ライン
{{ 選手名 }}	①尾崎
{{ 過去成績 }}	15

生成したテキスト情報例

実際に生成したテキスト情報の例と既存のテキスト情報を表 4.9 に示す。既存のテキスト情報はオッズパーク [73] より引用した。

生成したテキスト情報の例から 4.3.1 節で設定した目標が達成できているということがわかる。どの生成したテキスト情報も本命と対抗の 2 つの予想が記述されており、生成したテキスト情報 1 と生成したテキスト情報 2 については穴として配当の期待値が高い予想が記述されている。生成したテキスト情報 2 の「ラスト半週の捲り」や生成したテキスト情報 3 の「バック取りから 1 着」といった、レース展開が記述されている。生成したテキスト情報 1 の「中国ラインから」や生成したテキスト情報 2 の「番手⑨竹内がマーク」といった、ラインに関する情報が記述されている。生成したテキスト情報 1 の「出場選手内で最高の直近 4ヶ月競争得点 (114.1) を誇る」や生成したテキスト情報 3 「直近 4ヶ月バック数が二番目に多い (14 本)」といった選手に関する情報が記述されている。

生成したテキスト情報は事前に設定したテンプレートから生成しているため、人間が書いている既存のテキスト情報よりも文章のバリエーションが少ない。テンプレートのパターンを増やすことで改善はするが、設定は人手によって行う必要があるため限界がある。この点は開発システムの課題の一つである。

4.3.3 生成したテキスト情報の評価実験

本節では、生成したテキスト情報を評価した実験について示す。本実験の目的は生成したテキスト情報がドメインエキスパートから見て有用かを検証することである。

表 4.8: テンプレートの使用条件

種類	使用条件の軸	条件 (C) とテンプレート (T) の例
本命	ライン	C: 二車単に含まれる選手のラインが同じ T: 本命は {{ 投票券 }}. {{ ライン名 }} から {{ 選手名 1 }} と {{ 選手名 2 }} でワンツー.
	レース展開	C: レース展開が捲り T: 本命は {{ 投票券 }}. {{ 選手名 1 }} のラスト半周の捲りに期待. {{ 選手名 2 }} がマーク.
	対抗との確率の差	C: 本命と対抗の確率が僅差 T: 接戦だが本命は {{ 投票券 }}. {{ 選手名 2 }} の自力から, {{ 選手名 1 }} の差しに期待.
	穴との一致	C: 本命と穴の投票券が一致 T: 本命は {{ 投票券 }}. オッズも {{ オッズ }} と高く高配当の期待大. {{ 選手名 1 }} の自力から, {{ 選手名 2 }} の差しに期待.
対抗	本命との選手の一致	C: 本命と対抗の 1 着選手が一致 T: 対抗は {{ 投票券 }}. {{ 選手名 2 }} にも警戒.
穴	確率とオッズ	C: 確率が 1% 以下 T: 穴は {{ 投票券 }}. 的中確率は {{ 確率 }} と低いがおッズ {{ オッズ }} の万車券.

実験設定

生成したテキスト情報と既存のテキスト情報を車券販売サービス会社の社員 10 名により, 生成したテキスト情報と既存のテキスト情報をそれぞれ 50 件, 5 段階のリッカート尺度 (5: 非常にそう思う, 4: そう思う, 3: どちらかといえばそう思う, 2: どちらかといえばそう思わない, 1: そう思わない) で評価した. 評価項目として, 第 1 章で示したように, 本稿においてテキスト情報に重要であると考え「初心者にも理解可能か」, 「車券購入の助けになるか」, 「記事として面白いか」の 3 項目を使用した. 評価者には, テキスト情報のみを提示したため, 記述された予想が正解しているかどうかは評価には含まれていない.

実験に使用した 50 件の生成したテキスト情報におけるテンプレートの異なり数は, 本命単独では 19, 対抗単独では 6, 穴単独では 4, 3 つを組み合わせた場合は 39 だった.

表 4.9: 生成したテキスト情報と既存のテキスト情報の例

既存のテキスト情報 1	⑦松浦は末の粘りを欠いたが、積極的に攻める姿勢は評価。細切れなら展開追い風。好位から仕留め、③柏野と決める。⑥加賀山が突進。①福田が差し脚伸ばす。
生成したテキスト情報 1	本命は 7-3。中国ラインから出場選手内で最高の直近 4ヶ月競争得点 (114.1) を誇る⑦松浦と 2 着数が二番目に多い (6 回) ③柏野でワンツー。対抗は 1-9。1 着数が二番目に多い (12 回) ①福田と⑨大塚にも警戒。穴は 6-1。的中確率 1.6% に対しオッズ 239.9 と配当期待値大。
既存のテキスト情報 2	松岡、竹内岐阜コンビのワンツー期待するが直線勝負となれば鹿内も単可能。八尋穴狙いで。
生成したテキスト情報 2	接戦だが本命は 2-9。直近 4ヶ月競争得点が二番目に高い (102.4) ②松岡のラスト半周の捲りに期待。番手⑨竹内がマーク。対抗は 1-6。出場選手内で最高の競争得点 (104.3) を誇る①鹿内と⑥山崎にも警戒。穴は 4-1。的中確率 3.6% に対しオッズ 48.5 と配当期待値大。
既存のテキスト情報 3	前回は完全優勝を達成するなど、着実に力を付けている久樹が地脚生かして逃切る。同県尾崎が追走も平川とのパワー勝負を本線に。
生成したテキスト情報 3	本命は 5-1。直近 4ヶ月バック数が二番目に多い (14 本) ⑤久樹がバック取りから 1 着。番手①尾崎がマーク。対抗は 2-4 での的中確率 17.9%。出場選手内で最大の 1 着数 (14 回) を誇る②平川と④鈴木にも警戒。

結果・考察

評価者全体の評価結果を図 5.1 に示す。「初心者にも理解可能か」と「車券購入の助けになるか」の項目については、生成したテキスト情報は既存のテキスト情報と比較して高い評価を得た。「記事として面白いか」の項目については、生成したテキスト情報は既存のテキスト情報と同等の評価を得た。

各評価項目について評価者 10 人の平均評価値が最大の記事を表 4.10 に示す。「初

心者にも理解可能か」と「車券購入の助けになるか」の項目について最大の評価を得たのは生成したテキスト情報だった。「記事として面白いか」の項目について最大の評価を得たのは既存のテキスト情報であり、選手の競輪選手になる前の情報など生成したテキスト情報では記述できないような選手の情報が記述されている。既存のテキスト情報の多くは、文字数に強い制約がある新聞のテキスト情報の引用であるため、評価の低いテキスト情報が存在するが、「記事として面白いか」の項目で最大の評価を得たテキスト情報のように、少ない文字数に収めるという制約がない場合には、人間の著者は評価の高いテキスト情報を生成可能である。

評価者別に生成したテキスト情報と既存のテキスト情報のどちらのテキスト情報に高い評価をつけたかを表 4.11 に示す。「初心者にも理解可能か」と「車券購入の助けになるか」の項目については、殆どの評価者が生成したテキスト情報に既存のテキスト情報よりも高い評価をしているのに対し、「記事として面白いか」の項目については、評価者によってどちらのテキスト情報を高く評価するか意見が割れる。

既存のテキスト情報には無い生成したテキスト情報の特徴として、予測結果の明記や推定した生起確率の記述、オッズに基づく配当期待値の高い車券の記述などが挙げられる。これらの特徴が「初心者にも理解可能か」と「車券購入の助けになるか」の項目に対して高く評価されたものと考えられる。表 4.9 の既存のテキスト情報 1 の「⑥加賀山が突進。①福田が差し脚伸ばす。」や既存のテキスト情報 2 の「八尋穴狙いで。」のように、既存のテキスト情報では文字数の制約を満たすために情報を省略した短い文章によって予想を記述することがあり、こういった記述が初心者の理解の難しさの原因として考えられる。一方で、生成したテキスト情報では「本命は 7-3。」や「対抗は 1-9。」のように予測結果を明記しているという特徴があり、この特徴が「初心者にも理解可能か」の項目で高く評価された要因の一つであると考えられる。また、購入金額を上回る配当を得るためには、オッズと確率に基づいて配当の期待値を考慮する必要がある。表 4.9 の生成したテキスト情報 3 の「対抗は 2-4 での的中確率 17.9%。」や生成したテキスト情報 2 の「穴は 4-1. 的中確率 3.6% に対しオッズ 48.5 と配当期待値大。」のように、生成したテキスト情報には推定した生起確率の記述やオッズに基づく配当期待値の高い車券の記述といった特徴があり、この特徴が「車券購入の助けになるか」の項目で高く評価された要因の一つであると考えられる。「記事として面白いか」の項目については、評価者によってどちらの記事を高く評価するか意見が割れており、生成したテキスト情報の特徴を面白い記事と考えるか否かは、個人差がある。

表 4.10: 評価者 10 人の評価値の平均値が最大のテキスト情報

評価項目 (平均値)	テキスト情報
初心者にも 理解可能か (3.9)	[生成したテキスト情報] 本命は 1-5 での的中確率 16.2%. 出場選手内で最大の直近 4ヶ月捲り数 (9 回) を誇る①菅谷の自力に期待. 二連対率 31.8%の⑤太田が続いて関東ラインでワンツー. 対抗は 9-7 での的中確率 7.7%. 競争得点 90.8 の⑨藤岡と⑦中石にも警戒. 穴は 2-4. 的中確率 6.4%に対しオッズ 30.2 と配当期待値大.
車券購入の 助けになる か (4.1)	[生成したテキスト情報] 本命は 4-7. 出場選手内で最大の直近 4ヶ月 1 着数 (8 回) を誇る④ブフリがバック取りから 1 着. 番手⑦安部がマーク. 対抗は 4-8. ⑧山岸にも警戒. 穴は 8-1. 的中確率 4.3%に対しオッズ 142.9 と配当期待値大.
記事として 面白い か (4.2)	[既存のテキスト情報] 初日は開幕戦を走り、菅田謙仁の逃げを物の見事に捲り、この⑦ (中畑) を引き離した① (大城)、大学迄はボクシングをやり、25才から自転車競技に転向、9回目と言う事は9年間試験を受け続けた苦労人は根性が違うので必ずS級戦士に成るのでは. 準決勝はエリート橋本瑠偉・佐伯亮輔には歯が立たなかったが、攻めてはいたので、⑤ (菱沼) とのパワー争いは制すのでは. (中畑) が再度マーク. 来期の2班は決めてる (菱沼) は力不足は否めないが、積極的に攻めてるのは好感度大. ② (瀧野) ④ (砂川) で追走.

4.4 ニューラル言語モデル (GPT-2) による生成手法の性能の検証

本節では、様々な文章生成タスクにおいて高い性能を示している深層学習を用いてテキスト情報を生成する実験を行う。競輪のテキスト情報において、生成される記事の正確さの点から、4.3節で示したルールベース手法がより有効であることを示す。

4.4.1 実験設定

4.3節の実験で使用した50レースについて、深層学習による生成器によってテキスト情報を生成し、生成したテキスト情報の入力に対する正確さと可読性を評価した。




図 4.3: 評価者全体の評価値の頻度分布

ニューラル言語モデル (GPT-2) による生成器

事前学習済みの言語モデルである GPT-2 を Data-to-Text に適用した Harkous らの手法 [77] を基に生成器を学習させた。Harkous らの手法は、Data-to-Text における構造化データと説明文をテキストとして結合し、説明文に対応する部分のみを誤差計算の対象とした自己回帰により事前学習済み GPT-2 をファインチューニングする。推論時には、構造化データに対応するテキストのみを入力することで説明文に対応する出力を得る。Harkous らは GPT-2 による説明文の生成器に加えて、生成文を入力にとり意味的な忠実度を出力する分類器を使用しているが、本稿では GPT-2 による生成器のみを使用した。

Data-to-Text の入力にあたる構造化データとしてレースで上位に到着すると予測された選手名と Web 上の出走表で公開される情報（競輪場、選手の情報、ラインの情報）を使用した。学習時には既存のテキスト情報に出現する選手を予測結果として入力の構造化データに与え、推論時には予測器の出力から選択した本命、対抗の選手を予測結果として入力に与えることで、機械学習による予測結果に基づくテキスト情報を生成した。

日本語の文章を用いた GPT-2 の事前学習済みモデルとして、rinna 社が公開す

表 4.11: 評価者別の結果. 生成したテキスト情報の評価値が既存のテキスト情報より高い割合 (>), 同じ割合 (=), 低い割合 (<).

ID	初心者にも 理解可能か			車券購入の 助けになるか			記事として 面白いかな		
	>	=	<	>	=	<	>	=	<
0	0.88	0.08	0.04	0.86	0.14	0.00	0.56	0.28	0.16
1	0.90	0.08	0.02	0.90	0.10	0.00	0.68	0.22	0.10
2	0.98	0.02	0.00	1.00	0.00	0.00	0.20	0.50	0.30
3	0.24	0.24	0.52	0.76	0.22	0.02	0.06	0.54	0.40
4	0.58	0.24	0.18	0.62	0.30	0.08	0.10	0.20	0.70
5	0.78	0.14	0.08	0.92	0.08	0.00	0.68	0.26	0.06
6	0.74	0.26	0.00	0.92	0.08	0.00	0.68	0.24	0.08
7	0.48	0.44	0.08	0.42	0.54	0.04	0.26	0.44	0.30
8	0.22	0.66	0.12	0.66	0.34	0.00	0.56	0.34	0.10
9	0.48	0.24	0.28	0.60	0.32	0.08	0.12	0.14	0.74

るモデル²を使用した. ファインチューニングの前に, 事前学習済みモデルの語彙に含まれず既存のテキスト情報に出現する単語と, 構造化データをテキスト化する際に使用した特殊トークンをモデルの語彙に追加した. 学習には, 2014年1月1日から2018年5月31日の86,605レースを訓練データとして使用した. 訓練データの1割を検証データとして, エポック毎に検証データに対する誤差を計算し, 誤差が最小となるエポックでの結合重みを最終的な生成器として選択した.

評価項目

入力された構造化データに対する生成したテキスト情報の正確さとして構造化データに含まれない情報の記述の有無で評価した. 生成したテキスト情報の可読性を3段階(3: 日本語として読むことができる文章である, 2: 日本語として読むことはできるが同じ単語やフレーズの繰り返しなどの軽度な文法的誤りがある, 1: 日本語として読むことができない重度な文法的誤りがある)で評価した.

4.4.2 結果・考察

入力された構造化データに含まれない情報を記述した生成したテキスト情報は50件中42件だった. 各テキスト情報の可読性についての評価の平均値は2.82で, 評

²<https://huggingface.co/rinna/japanese-gpt2-medium>

表 4.12: GPT-2 による生成例と評価結果

生成したテキスト情報 1	◎渡辺は積極的に主導権をとり押切ろう○松山がマーク△栗田が好位狙うか捲り追込×太田マークの線 (正確さ: ○, 可読性: 3)
生成したテキスト情報 2	特選制す吉武が実力発揮! 久米が追走で地元両者のワンツーか. 波乱あれば中部コンビ. (正確さ: ×, 可読性: 3)
生成したテキスト情報 3	吉田に乗れる大西の勝機と見たが, 三重, 三重勢の反撃必至. (正確さ: ×, 可読性: 2)

表 4.13: 生成したテキスト情報 1 で GPT-2 の入力に使用した構造化データ (選手の情報)

draw	name	prefecture	age	point	back	escape	pursuit	last pursuit	mark	result3
1	神開将暢	福岡	45	82.1	0.00	0.00	0.00	0.00	0.12	6,5,6
2	渡辺大剛	京都	28	84.9	0.55	0.17	0.10	0.00	0.00	6,5,7
3	太田雅之	三重	40	83.2	0.00	0.00	0.00	0.04	0.00	7,6,5
4	栗田万生	unknown	24	79.8	0.68	0.42	0.06	0.00	0.00	6,6,2
5	松山勝久	福井	43	80.8	0.00	0.00	0.00	0.00	0.10	7,2,5
6	高尾剛文	福岡	49	70.5	0.00	0.00	0.00	0.03	0.00	9,8,8
7	山本貴喜	大阪	41	80.5	0.03	0.03	0.00	0.10	0.03	8,8,8
8	浅見敏也	愛知	48	78.9	0.00	0.00	0.00	0.00	0.06	7,7,3
9	中山敬太郎	熊本	29	80.2	0.06	0.00	0.06	0.06	0.00	8,7,3

価値が 3 のテキスト情報が 42 件, 2 のテキスト情報が 7 件, 1 のテキスト情報が 1 件だった. 生成したテキスト情報例を表 4.12 に示す. 表 4.12 の生成したテキスト情報 1 の入力に使用した構造化データを表 4.13, 4.14, GPT-2 の入力に使用したテキストを表 4.15 に示す. 生成したテキスト情報 1 では, 構造化データで上位に到着すると予想された選手名 (<prediction>2,5,4,3) が生成したテキスト情報中で正しく記述されており, そのラインや選手の情報に関する記述についても間違いはなく, 入力に含まれない情報は生成したテキスト情報に含まれていない. 生成したテキスト情報 2 では, 入力データに含まれない「特選制す」といった選手情報が記述されていることから, 事実に基づかないテキスト情報が出力されたといえる. 生成したテキスト情報 3 では, 三重という単語の繰り返しといった軽度な文法的誤りがある. 以上の結果から, GPT-2 は既存のテキスト情報に近い流暢な文章が生成可能である一方で, 入力された構造化データに含まれない情報を記述する傾向があることが確認できる. そのため, 本研究のようにテキスト情報の正確さが重要な場面では, 正確さが保証されるルールベース手法が有効であると考えられる.

表 4.14: 生成したテキスト情報 1 で GPT-2 の入力に使用した構造化データ (予測, 競輪場, ラインの情報)

prediction	2,5,4,3
track	名古屋
line	(9,1,6)(2,5,7)(4,3,8)

4.5 まとめ

本章では, 第 3 章で生成したレース展開情報を元にユーザにとって有用なテキスト情報を生成した. 意思決定問題としての特徴と Web サイトで配信された既存のテキスト情報を分析し, 生成するテキスト情報の目標を設定した. 事前に人手で設定したテンプレートを用いる手法によってテキスト情報を生成した. 評価実験によって生成したテキスト情報がドメインエキスパートから見て有用であることを示した. また既存のテキスト情報を学習データとして使用してニューラル言語モデルの一つである GPT-2 を fine-tune した結果, 既存のテキスト情報に近い流暢なテキストを生成可能な一方で, 入力に含まれない情報を記述する事例が確認された.

表 4.15: 生成したテキスト情報 1 で GPT-2 の入力に使用したテキスト

```

<data> <prediction>2,5,4,3 <track> 名古屋 <cyclist> ( <draw>1
<name> 神開将暢 <prefecture> 福岡 <age>45 <point>82.1 <back>0.00
<escape>0.00 <pursuit>0.00 <last_pursuit>0.00 <mark>0.12
<result3>6,5,6) ( <draw>2 <name> 渡辺大剛 <prefecture> 京都 <age>28
<point>84.9 <back>0.55 <escape>0.17 <pursuit>0.10 <last_pursuit>0.00
<mark>0.00 <result3>6,5,7) ( <draw>3 <name> 太田雅之 <prefecture>
三重 <age>40 <point>83.2 <back>0.00 <escape>0.00 <pursuit>0.00
<last_pursuit>0.04 <mark>0.00 <result3>7,6,5) ( <draw>4 <name> 栗田万
生 <prefecture>unknown <age>24 <point>79.8 <back>0.68 <escape>0.42
<pursuit>0.06 <last_pursuit>0.00 <mark>0.00 <result3>6,6,2) (
<draw>5 <name> 松山勝久 <prefecture> 福井 <age>43 <point>80.8
<back>0.00 <escape>0.00 <pursuit>0.00 <last_pursuit>0.00 <mark>0.10
<result3>7,2,5) ( <draw>6 <name> 高尾剛文 <prefecture> 福岡 <age>49
<point>70.5 <back>0.00 <escape>0.00 <pursuit>0.00 <last_pursuit>0.03
<mark>0.00 <result3>9,8,8) ( <draw>7 <name> 山本貴喜 <prefecture>
大阪 <age>41 <point>80.5 <back>0.03 <escape>0.03 <pursuit>0.00
<last_pursuit>0.10 <mark>0.03 <result3>8,8,8) ( <draw>8 <name> 浅見
敏也 <prefecture> 愛知 <age>48 <point>78.9 <back>0.00 <escape>0.00
<pursuit>0.00 <last_pursuit>0.00 <mark>0.06 <result3>7,7,3) (
<draw>9 <name> 中山敬太郎 <prefecture> 熊本 <age>29 <point>80.2
<back>0.06 <escape>0.00 <pursuit>0.06 <last_pursuit>0.06 <mark>0.00
<result3>8,7,3) <line>(9,1,6)(2,5,7)(4,3,8) <text>

```

第5章

個人化された情報の有効性の検証

5.1 はじめに

現実の意思決定の多くは多目的であり、ユーザは様々な要素を考慮して意思決定を行う。そのため、ユーザの意思決定において有用な情報はユーザごとに異なることが想定される。本章では、全てのユーザに対して同じ情報を提示するのではなく、それぞれに適切な情報を提示する個人化された情報を有効性を検証する。第4章では、公営競技の投票券購入という意思決定において代表的な要素である配当金の獲得に注目し、ユーザにとって有用なテキスト情報を生成した。本章では、公営競技の投票券購入において代表的な要素の一つである選手の応援に注目し、ユーザにとって有用なテキスト情報を生成する。ドメインエキスパートによる実験によって生成したテキスト情報の有用性を評価する。

本章では、5.2節で公営競技の投票券購入を行うユーザについて示す。5.3節では、個人化されたテキスト情報の生成手法について示す。5.4節では、ドメインエキスパートによるテキスト情報の評価実験について示す。5.5節、では本章のまとめを示す。

5.2 競輪における代表的なユーザタイプ

本節では、競輪の投票券購入という意思決定の状況の特徴に基づいて、個人化の対象とする代表的なユーザタイプについて示す。

5.2.1 スポーツ競技

競輪は自転車を使用したトラックレースである。レースは最大9人で行い、バンクと呼ばれる競走路を周回し、1,500mから3,000mの距離を走破する速さを競う。競輪のレースは毎日約50レースほど開催されている日本の中では比較的人気なプロスポーツ競技である。

競輪にはその他のトラックレースにはないラインと呼ばれるチームに近い要素が存在する。選手はレース中にラインと呼ばれる縦列を形成し、協力しながらレースを進める。最後のゴール前の直線までは、同一ラインの選手で協力して走るが、最後は同一ラインの選手とも競い、各個人が1着を目指す。同じ地域に所属する選手同士でラインを組みることが多く、どの選手同士がラインを組むという情報はレース開始前に公開される情報である。

5.2.2 公営競技

日本における競輪は公的機関が賭博として開催するスポーツである。観客はレース結果を予想した投票券（車券）を購入し、予想が正解した場合に配当金を受け取る。競輪の車券はパリミュチュエル方式によって販売されており、配当金の倍率であるオッズは観客全体の投票割合によって決定される。競輪の賭式は全部で7種類あり、代表的なものに、1着と2着の選手を着順通りに予想する賭式（二車単）、1着から3着の選手を着順通りに予想する賭式（3連単）がある。予想をテキストとして表記する慣習として1着が選手番号1の選手で2着が選手番号2の二車単を示す場合1-2と表記する。

5.2.3 ユーザの行動・情報・行動

競輪におけるユーザの行動は購入する投票券とその金額である。ユーザが意思決定をする際に受け取る情報は様々であり、代表的な情報として選手の過去成績などを示した出走表や各投票券のオッズといったテーブルデータ、専門家が自身の予想を記述する記事といったテキストデータなどが挙げられる。競輪におけるユーザの効用は、様々な要素から構成される複合的な効用である。代表的な効用として、選択した行動に応じて得られる配当金（外発的効用）と選手を応援するといったスポーツ観戦を楽しむ効用（内発的効用）が挙げられる。本論文では、公営競技の投票券購入という意思決定における効用を構成する要素として代表的な2つの効用に注目し、それぞれの効用を重視するユーザに対して高い効用が得られるような情報を提示する文章生成器を開発した。レース結果を予想し配当金を得ることを重視するユーザ（predicting-oriented users）とレースを観戦し楽しむことを重視するユーザ（viewing-oriented users）の2つのユーザタイプを想定して、テキスト情報生成を行う。predicting-oriented users に対するテキストとして、レース結果の予測情報とそれに関わる選手の過去成績情報やライン情報を記述する。viewing-oriented users に対するテキストとして、ある選手の特徴的な情報やより個人的なプライベートな情報（予想に大きな影響を与えるとは思えないような情報）を記述することと

した。

5.3 テキスト情報の生成手法

本章では第4章で示した文章生成器を拡張によって個人化機能を持つ文章生成器を開発した。テキスト情報の生成手法は第4章と同様に事前に人手で設定しておいたテンプレートを用いるルールベース手法である。テンプレートにはスロットが用意されており、スロットに選手名や選手の過去成績といった対応する値を代入することで文章を生成する。

5.3.1 テキスト情報の生成に使用したデータ

テキスト情報の生成に使用するデータは競輪に関する公開データと公開データの変換によって得られるデータの2つに大別される。

公開データとして、選手の過去成績や個人的な情報、オッズやラインの情報などを使用した。選手の過去成績として、直近4ヶ月の1着率や連帯率、前回の順位、通算勝ち数などを使用した。選手の個人的な情報として、誕生日や好きな食べ物、過去のスポーツ経験などを使用した。先行研究では選手の個人的な情報は取り扱っていなかったため、選手の個人的な情報を公開しているWebサイト [78] からスクレイピングを行い、新たにデータベースを構築した。選手の個人的な情報として、身長や体重などの身体的特徴、練習仲間や師弟などの交友関係、好きな食べ物、養成所時代の成績や学生時代のスポーツ歴などの情報が収集された。

公開データから得られる変換データとして、第3章で示した機械学習モデルによるレース展開予測器の出力を使用した。予測器の出力として、選手の最終半周の時点で1着である確率と1着確率、二車単の生起確率、選手の最終半周の時点で1着の選手で条件付けた1着確率を使用した。予測器は出場選手の系列 $\mathbf{x} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_9]$ を入力として、レース結果の系列 $\mathbf{y} = [y_0, y_1, y_2, y_3]$ を予測するように学習させた。ここで、 \mathbf{x}_i は車番 i の選手を表す特徴ベクトル、 y_0 はバック取り選手の車番、 y_1, y_2, y_3 は1, 2, 3着の選手の車番である。モデルとして Transformer Encoder-Decoder を使用し、選手の特徴ベクトルとして競輪場の情報や選手の過去成績、ラインの関係性などを使用した。2013年から2018年の5年分の約100,000レースの訓練データで学習し、2019年の1年分の約20,000レースのテストデータで評価した結果、オッズと同等以上の予測正解率を達成し、配当金の期待値を考慮して投票券を購入することで100%を超える回収率を達成した。

これらのデータはテンプレート中のスロットへの値の当てはめとテンプレートの使用可否の判断に使用した。

5.3.2 テキスト情報の生成に使用したテンプレート

predicting-oriented Users と viewing-oriented Users について、それぞれにユーザーに向けたテキスト情報を生成するためのテンプレートを設定した。

Predicting-Oriented Users 用のテンプレート

predicting-oriented users 向けのテキスト情報は第 4 章で開発されたものと同様である。predicting-oriented users 向けのテンプレートとして、レース結果の予測情報とそれに関わる選手の過去成績情報やライン情報を記述するテンプレートを設定した。設定したテンプレートの基本的な構成とテンプレートの例を以下に示す。

的中確率が最も高いと予測された車券の情報

本命は {{ 車券 }} での中確率 {{ 確率 }}。{{ ライン名 }} から {{ 選手名 1 }} と {{ 選手名 2 }} でワンツー。

的中確率が 2 番目に高いと予測された車券の情報

対抗は {{ 車券 }} での中確率 {{ 確率 }}。{{ 選手名 }} にも警戒。

配当の期待値が高い車券の情報

穴は {{ 車券 }} 的中確率 {{ 確率 }}% に対しオッズ {{ オッズ }} と配当期待値大。

Viewing-Oriented Users 用のテンプレート

viewing-oriented Users 向けのテンプレートとして、ユーザーがレース観戦の際に選手に注目するきっかけになるような個人的な情報を記述するテンプレートを設定した。通算勝ち数・通算出場数が節目に近い選手、誕生日に近い選手を記述するテンプレートを設定した。選手の個人的な情報として、好きな食べ物、嫌いな食べ物、養成所時代の成績、学生時代のスポーツ歴の情報を使用した。設定したテンプレートの基本的な構成とテンプレートの例を以下に示す。

選手の誕生日や節目のレース数の情報

今日勝てば通算勝ち数 {{ milestone win cumsum }} 回となる {{ cyclist name only }}。

選手の前回レースの結果と今回レースの予測勝率の情報

前回のレースでは {{ 前回順位 }} 着と惜しい結果だったが、今日のレースでの予測勝率は最も高い {{ 今回予測勝率 }} で前回のリベンジのチャンス。

選手のより個人的な情報

中学時代は {{ sports1 }}、高校時代は {{ sports2 }} をしていた。好きな食べ物 {{ food1 }}、嫌いな食べ物は {{ food2 }}。

5.4 生成したテキスト情報の評価実験

本節では人間のエキスパートによる生成文の評価実験について説明する。本実験の目的は、生成したテキスト情報がドメインエキスパートから見て有用かを検証することである。

5.4.1 実験設定

実験の目的は開発した個人化機能を持つ文章生成器が、ある意思決定のシナリオにおいて、各ユーザ群に対して効用を最大化することが可能かを評価することである。しかし、実際に意思決定をするユーザに対して情報提示をし、ユーザの得られた効用を測定することは困難である。そのため、本研究ではその評価の第一段階として、提示された情報がユーザにとって価値のある情報か？という設問にエキスパートに回答させることで情報を評価した。

生成された2種類のテキスト情報のそれぞれ10サンプルが、ドメインエキスパート5人によって評価された。評価者は全員、競輪の投票券を販売するサービスを提供する会社の社員でプライベートで競輪を楽しむユーザである。評価者は5段階のリッカート尺度（5:非常にそう思う, 4:そう思う, 3:どちらかといえばそう思う, 2:どちらかといえばそう思わない, 1:そう思わない）で2つの設問に回答した。1人の評価者が2つのユーザタイプの視点で設問に回答した。設問は「レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?」、 「レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?」とした。評価者には、テキスト情報のみを提示したため、記述された予想が正解しているかどうかは評価には含まれていない。実験に使用したテキストは日本語で書かれたテキストであり、評価者は全員日本語ネイティブだった。

各生成文の評価値の代表値について差の有無を検討するために、Brunner-Munzel検定を実施した。全ての検定において有意水準は5%とした。2つの設問についてそれぞれ検定を実施するため、ボンフェロニ補正によって補正された有意水準2.5%を使用した。

また、実験終了後に評価者に対して、各ユーザグループにとって価値のある情報として適切だと考える情報は何かフィードバックを依頼した。

実験に使用したテキスト情報を以下に示す。

5.4.2 結果・考察

各設問における評価者全体の評価値の頻度分布を図 5.1, 評価値の平均値と中央値を表 5.1 に示す. Brunner-Munzel 検定の結果, 「レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?」 ($p\text{-value} = 5.4e-17 < 0.025$) と 「レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?」 ($p\text{-value} = 0.023 < 0.025$) の両方で有意な差が検出された. predicting-oriented users 向けのテキスト情報は設問 「レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?」 の評価値の平均値が 3.64, viewing-oriented users 向けのテキスト情報は設問 「レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?」 の評価値の平均値が 3.38 と, どちらも 3 以上の良い評価を得た. これらの結果は, 個人化されたテキスト情報の有効性を示している.

表 5.2 は, 「レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?」 という設問に対する平均点が最も高い, および最も低い predicting-oriented users 向けのテキストの例を示している. 表 5.3 は, 「レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?」 という設問に対する平均点が最も高い, および最も低い viewing-oriented users 向けのテキストの例を示している. predicting-oriented users 向けのテキスト情報についてのスコア 「レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?」 は半数以上が 4 もしくは 5 だった. 反対に, viewing-oriented users 向けの文章についてのスコア 「レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?」 は半数以上が 2 もしくは 3 だった. 実験後の評価者からのフィードバックでは, 先日誕生日であった選手の情報と節目の出場数が近い選手の情報について価値のある情報として適切であると回答した評価者はそれぞれ 2 人だった. このことから, 今回設定した viewing-oriented users 向けのテンプレートの内容が一部の評価者には適切ではないと判断されたことが, viewing-oriented users 向けの文章の評価値が比較的 low だった原因の一つであると考えられる.

5.5 まとめ

本章では, 意思決定において有用な情報はユーザごとに異なることがあるという背景に基づいて, 異なるユーザに対して適切なテキスト情報を提示する個人化された情報の有効性を検証した. 第 4 章で生成した配当金の獲得に有用と思われるテキスト情報 (predicting-oriented users) に加えて, 選手の応援に有用と思われるテキスト情報 (viewing-oriented users) を生成した. 選手の応援に有用なテキスト情報として, レースの展開とは関連性が低いユーザが注目すると想定される選手の個人

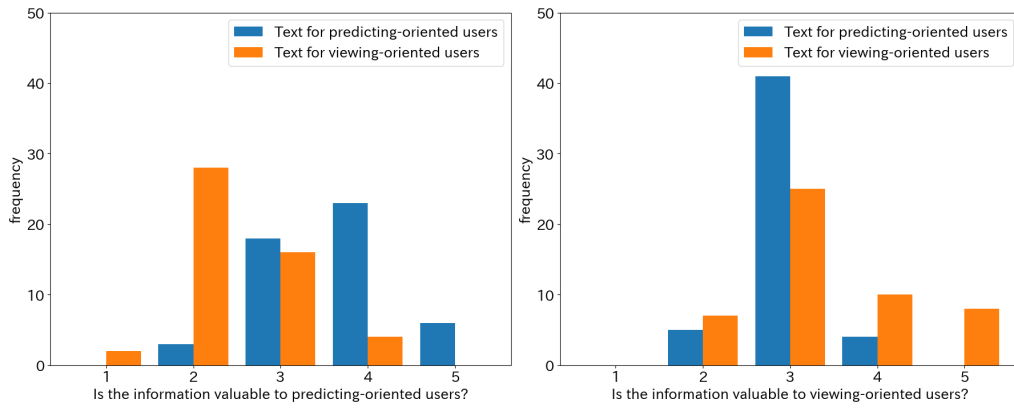


図 5.1: 各設問における評価値の頻度分布. レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か? ("Is the information valuable to predicting-oriented users?") とレースを観戦し楽しむことを重視するユーザにとって価値のある情報か? ("Is the information valuable to viewing-oriented users?") について.

表 5.1: 各設問における評価値の平均値と中央値

		レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?		レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?	
		mean	median	mean	median
text for predicting-oriented users		3.64	4	2.98	3
text for viewing-oriented users		2.44	2	3.38	3

的な情報を含むテキスト情報を生成した. 評価実験によって生成したテキスト情報がドメインエキスパートから見て有用であることを示した. また, 2つのユーザタイプの視点でそれぞれ異なるテキスト情報が有用と評価されることを示し, 競輪の投票券購入という意思決定の状況において, 個人化された情報の有効性を示した.

表 5.2: predicting-oriented users 向けのテキスト情報の例 と各評価者の評価値 (レース結果を予想し配当金を得ることを重視するユーザにとって価値のある情報か?). eval i は評価者 ID i の評価値を示す.

text	eval 0	eval 1	eval 2	eval 3	eval 4
本命は的中確率 49.0%の 7-2 で決まり. 出場選手内で最高の直近 4ヶ月二連対率 (95.7%) を誇る②ボスのラスト半周の捲りから, ⑦グレーツァーの差しに期待. ②ボスの逆転 (2-7) の確率は 25.2%. 穴は 7-3. 的中確率 3.5%に対しオッズ 30.3 と配当期待値大.	4	5	5	3	4
本命は 1-5 での的中確率 9.3%. ⑤玉村ラインから出場選手内で最高の直近 4ヶ月競走得点 (91.6) を誇る①表原と⑤玉村でワンツー. 対抗は 2-9 での的中確率 9.2%. 出場選手内で最大のバック数 (11 本) を誇る②笠松と⑨高橋にも警戒.	4	3	4	3	2

表 5.3: viewing-oriented users 向けのテキスト情報の例 と各評価者の評価値（レースを観戦し楽しむことを重視するユーザにとって価値のある情報か?）。eval i は評価者 ID i の評価値を示す。

text	eval 0	eval 1	eval 2	eval 3	eval 4
1 日後の 10 月 6 日が 32 歳の誕生日となる⑨高倉。前回のレースでは 6 着と残念な結果だったが、今日のレースでの予測勝率は最も高い 27.3%で前回のリベンジのチャンス。中学時代は野球，高校時代は自転車競技をしていた。好きな食べ物はカレー，嫌いな食べ物はセロリ。	3	4	5	5	4
先日 (9 月 18 日) が 26 歳の誕生日だった④大西。前回のレースでは 6 着と残念な結果だった。今日のレースでの予測勝率は 6 位の 7.5%と高くない，厳しいレースが続くがここは頑張りどころ。中学時代は卓球，高校時代は自転車競技をしていた。好きな食べ物は肉・魚，嫌いな食べ物はゴーヤ。	3	2	3	4	2

第6章

結論

本論文では、ユーザの意思決定において有用な情報を生成に関する研究成果を示した。公営競技の一つである競輪の投票券購入という意思決定の状況を対象に研究を実施した。ユーザの意思決定において有用なテキスト情報の生成のために必要な研究項目として、テキスト情報の元となるデータの生成、テキスト情報の生成、ユーザモデリングおよびテキスト情報の個人化の3つの研究項目を扱った。

第3章では、テキスト情報の元となるデータの生成に関する研究として、機械学習による競輪のレース展開の予測を実施した。予測するレース展開は、最終半周時点で先頭の選手、1着の選手、2着の選手、3着の選手とした。ニューラルネットワークのTransformerを使用した予測器によって、精度が高いことが知られている確定オッズよりも高い予測精度を達成した。また、Transformerの出力する投票券的的中確率と確定オッズの積によって計算される配当金の期待値を考慮して購入する投票券を選択することで、100%を超える回収率が達成可能であることを示した。これらの結果から、競輪の投票券購入を行うユーザにとって有用なテキスト情報の生成のためのレース展開の予測が達成されたといえる。第4章では、第3章で生成したデータを使用して実際にユーザの意思決定において有用なテキスト情報を生成した。既存のテキスト情報の分析と意思決定問題の特徴からユーザにとって有用な情報を検討し、テンプレートを用いる手法によってテキスト情報を生成した。レース展開の情報とそれに関連する選手の情報やラインの情報、オッズの情報などを説明するテキスト情報を生成した。生成したテキスト情報について、評価実験によってドメインエキスパートから見て有用な情報であることを示した。第5章では、意思決定において有用な情報はユーザごとに異なるという背景のもと、個人化されたテキスト情報の有効性について検証した。第4章で生成したテキスト情報に加えて、レース展開とは関連性の低いと考えられる、選手のより個人的な情報を付加したテキスト情報を生成した。ドメインエキスパートによって、2種類の情報について2つのユーザタイプの視点で情報の有用性を評価した結果、各ユーザタイプ

によって有用な情報が異なることが示され、個人化されたテキスト情報の有効性が示された。

以上のことから、競輪の投票券購入を対象としたユーザの意思決定における有用な情報の生成が達成できたといえる。競輪の投票券購入は不確実な将来の予測や有用な情報がユーザによって異なるといった、その他の多くの現実の意思決定の問題がもつ一般的な特徴をもつ。そのため本論文で得られた研究成果は、その他の多くの現実の意思決定問題におけるユーザにとって有用な情報の生成に貢献することが期待される。具体的な応用例としては、気象情報の提示や金融商品に関する情報の提示、交通情報の提示、店舗の売上情報の提示などが挙げられる。本論文では、テキスト情報の元となるデータ生成として、競輪の過去のレースの履歴データを用いた機械学習によってレース展開の予測器を開発した。予測器の開発の際には、競輪のドメイン知識に基づいて予測器の入出力や入力特徴量を検討することで、高い精度を達成した。応用例に示した気象予測や株価予測、渋滞予測、売上予測においても本論文と同様に対象となるドメイン知識に基づいて、予測器の入出力や入力特徴量を検討することで、テキスト情報の元となるデータ生成が可能であると考えられる。また本論文では、データからテキスト情報の生成として、競輪の既存のテキスト情報の分析とドメイン知識に基づいて、テンプレートによるテキスト情報の生成器を開発した。テンプレートによる生成器の開発の際には、予測器の出力から生起確率の高い展開や配当の期待値が高い展開の情報をユーザにとって有用と考えられる情報として選択し、それらを説明するテンプレートを設定した。応用例に示した例においても、対象となるドメイン知識に基づいて、予測器の出力から有用な情報を選択しテンプレートを設定することで、有用なテキスト情報を生成することが可能であると考えられる。このように、本論文で行った機械学習を用いた予測器の開発、テキスト情報として記述する内容の選択およびテンプレートの設定を対象とするドメイン知識に基づいて行うことで、競輪以外のインスタンスへの応用が期待される。

今後の展望として、より多様なテキスト情報の生成、ユーザにとって有用なテキスト情報の自動推定、ユーザとの双方向のインタラクション、その他のインスタンスへの応用の4点が挙げられる。

本論文では競輪の投票券購入という意思決定において、配当金の獲得と選手の応援の2つに注目してテキスト情報を生成したが、この2つの要素以外を重視するユーザも存在する。また配当金の獲得と選手の応援を重視するユーザの中でも、高リスク・高リターンによる配当金の獲得を好むユーザや低リスク・低リターンによる配当金の獲得を好むユーザなど、多様なユーザが存在する。そうした多様なユーザに対応するためにはより多様なテキスト情報の生成が求められる。本論文では、

人手で設定したテンプレートを使用する手法によりテキスト情報を生成したが、本手法はより多様なテキスト生成には人手によるテンプレート設定のコストが大きい。多様なテキスト情報の生成には、GPT-4をはじめとする大規模言語モデルの活用が期待される。

本論文では、第5章でユーザごとに異なるテキスト情報を示すことの有効性を示した。これによりユーザのユーザタイプが明らかな場合には、各ユーザにより有用なテキスト情報を提示することが可能である。一方でユーザタイプが明らかでない状況で、ユーザに対して有用な情報を提示することが求められる場面も多く存在する。そのため、ユーザタイプの推定といったユーザにとって有用なテキスト情報を自動推定する技術が求められる。ユーザの属性やユーザの過去の行動や提示された情報に対するフィードバックに関する履歴データを使用した機械学習によるユーザ分類器の開発や、ユーザに関するデータが無い状況から始まりユーザに情報提示を行いながら動的にユーザに適切な情報を提示するバンディットアルゴリズムに基づく手法などが考えられる。こうした自動推定手法によって、ユーザの自身に関する情報を開示するコストや提示される複数の情報の中から必要な情報を選択するコストを減らすとともに、ユーザに対しより有用な情報を提供することが可能になることが期待される。

本論文では、システムからユーザへの一方的な情報提示を想定した研究を実施したが、対話形式によるユーザとの双方向のインタラクションも今後の展望として挙げられる。対話形式によるインタラクションによって、前述したユーザにとって有用な情報を推定するための情報をユーザから引き出すことなども可能となる。近年ではChatGPTといった対話形式に特化した大規模言語モデルなどが開発されており、こうした大規模言語モデルの活用によって対話形式による有用な情報の提示が期待される。

本論文では、競輪の投票券購入という意思決定の状況をインスタンスとして、ユーザの意思決定において有用なテキスト情報の生成に関する研究を実施した。本論文で得られた研究成果をその他のインスタンスに適用することが今後の展望として挙げられる。本論文で扱ったインスタンスの一般的な特徴として、将来の状態の不確実性や計算機によって得られた数値データをユーザに対して分かりやすいテキスト情報に変換すること、定量的に計算可能な金銭的報酬のほかに選手の応援といった要素が存在するといった点が挙げられる。共通した特徴を持つインスタンスとして、気象情報の提示や金融商品に関する情報の提示、交通情報の提示、売上情報の提示などが挙げられ、こうしたインスタンスに対して本論文の手法を適用することが今後の展望として挙げられる。

謝辞

本研究を進めるに当たり、様々なご指導を頂きました北海道大学大学院情報科学研究院 調和系工学研究室の川村秀憲 教授，山下倫央 准教授，横山想一郎 助教に深謝申し上げます。副査としてご指導いただいた知能ソフトウェア研究室の野田五十樹 教授，自律系工学研究室の山本雅人 教授，ヒューマンコンピュータインタラクション研究室の小野哲雄 特任教授に感謝申し上げます。多くのご助言，実験にご協力いただいた株式会社チャリ・ロトの関係者の皆様に感謝いたします。多くのご助言，ご支援を頂いた調和系工学研究室の皆様に感謝いたします。最後に，これまで支えてくれた家族と友人に感謝いたします。

参考文献

- [1] 福島 俊一. 複雑社会における意思決定・合意形成支援の技術開発動向. *人工知能*, 34(2):131–138, 2019.
- [2] 国立研究開発法人科学技術振興機構 研究開発戦略センター. 研究開発の俯瞰報告書 システム・情報科学技術分野 (2023 年) . <https://www.jst.go.jp/crds/pdf/2022/FR/CRDS-FY2022-FR-04.pdf>, Accessed on 11/25/2023.
- [3] Anna S. Law, Yvonne Freer, Jim Hunter, Robert H. Logie, Neil McIntosh, and John Quinn. A comparison of graphical and textual presentations of time series data to support medical decision making in the neonatal intensive care unit. *Journal of Clinical Monitoring and Computing*, 19(3):183–194, Jun 2005.
- [4] 伊藤 孝行, 鈴木 祥太, 山口 直子, 西田 智裕, 平石 健太郎, and 芳野 魁. 大規模合意形成支援システム. *システム／制御／情報*, 63(10):440–446, 2019.
- [5] 藤田 桂英. マルチエージェントシステムにおける自動交渉の研究動向. *システム／制御／情報*, 67(1):25–32, 2023.
- [6] 竹村 和久. 意思決定現象と行動意思決定論 (<特集>意思決定). *知能と情報*, 17(6):646–654, 2005.
- [7] Herbert A Simon. Administrative behavior: A study of decision-making processes in administrative organization. *Macmillan*, 1947.
- [8] Daniel Kahneman and Amos Tversky. Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2):263–291, 1979.
- [9] Richard H. Thaler and Cass R. Sunstein. *Nudge : improving decisions about health, wealth, and happiness*. Yale University Press, New Haven, United States, 2008.

- [10] Xiao Ding, Yue Zhang, Ting Liu, and Junwen Duan. Deep learning for event-driven stock prediction. In *Proceedings of the 24th International Conference on Artificial Intelligence, IJCAI'15*, page 2327–2333. AAAI Press, 2015.
- [11] Dou Wei. Prediction of stock price based on lstm neural network. In *2019 International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM)*, pages 544–547, 2019.
- [12] Chaojie Wang, Yuanyuan Chen, Shuqi Zhang, and Qiuhui Zhang. Stock market index prediction using deep transformer model. *Expert Systems with Applications*, 208:118128, 2022.
- [13] Afan Galih Salman, Bayu Kanigoro, and Yaya Heryadi. Weather forecasting using deep learning techniques. In *2015 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*, pages 281–285, 2015.
- [14] Suman Ravuri, Karel Lenc, Matthew Willson, Dmitry Kangin, Remi Lam, Piotr Mirowski, Megan Fitzsimons, Maria Athanassiadou, Sheleem Kashem, Sam Madge, Rachel Prudden, Amol Mandhane, Aidan Clark, Andrew Brock, Karen Simonyan, Raia Hadsell, Niall Robinson, Ellen Clancy, Alberto Arribas, and Shakir Mohamed. Skilful precipitation nowcasting using deep generative models of radar. *Nature*, 597(7878):672–677, Sep 2021.
- [15] Rory P. Bunker and Fadi Thabtah. A machine learning framework for sport result prediction. *Applied Computing and Informatics*, 15(1):27–33, 2019.
- [16] Johannes Stübinger, Benedikt Mangold, and Julian Knoll. Machine learning in football betting: Prediction of match results based on player characteristics. *Applied Sciences*, 10(1), 2020.
- [17] Elnaz Davoodi and Ali Reza Khanteymoori. Horse racing prediction using artificial neural networks. In *Proceedings of the 11th WSEAS International Conference on Neural Networks and 11th WSEAS International Conference on Evolutionary Computing and 11th WSEAS International Conference on Fuzzy Systems, NN'10/EC'10/FS'10*, pages 155–160, Stevens Point, Wisconsin, USA, 2010. World Scientific and Engineering Academy and Society (WSEAS).

- [18] David Edelman. Adapting support vector machine methods for horserace odds prediction. *Annals of Operations Research*, 151(1):325, Nov 2006.
- [19] Noah Silverman and Marc Suchard. Predicting horse race winners through a regularized conditional logistic regression with frailty. *Journal of Prediction Markets*, 7(1):43–52, 2013.
- [20] MD. Zakir Hossain, Ferdous Sohel, Mohd Fairuz Shiratuddin, and Hamid Laga. A comprehensive survey of deep learning for image captioning. *ACM Comput. Surv.*, 51(6), feb 2019.
- [21] Yizhe Zhang, Siqi Sun, Michel Galley, Yen-Chun Chen, Chris Brockett, Xiang Gao, Jianfeng Gao, Jingjing Liu, and Bill Dolan. DIALOGPT : Large-scale generative pre-training for conversational response generation. In Asli Celikyilmaz and Tsung-Hsien Wen, editors, *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics: System Demonstrations*, pages 270–278, Online, July 2020. Association for Computational Linguistics.
- [22] Yang Liu and Mirella Lapata. Text summarization with pretrained encoders. In Kentaro Inui, Jing Jiang, Vincent Ng, and Xiaojun Wan, editors, *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 3730–3740, Hong Kong, China, November 2019. Association for Computational Linguistics.
- [23] Thang Luong, Hieu Pham, and Christopher D. Manning. Effective approaches to attention-based neural machine translation. In *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, pages 1412–1421. Association for Computational Linguistics, 2015.
- [24] Jekaterina Novikova, Ondřej Dušek, and Verena Rieser. The E2E dataset: New challenges for end-to-end generation. In *Proceedings of the 18th Annual SIGdial Meeting on Discourse and Dialogue*, pages 201–206, Saarbrücken, Germany, August 2017. Association for Computational Linguistics.
- [25] Sam Wiseman, Stuart Shieber, and Alexander Rush. Challenges in data-to-document generation. In *Proceedings of the 2017 Conference on Empirical*

- Methods in Natural Language Processing*, pages 2253–2263, Copenhagen, Denmark, September 2017. Association for Computational Linguistics.
- [26] 村上 聡一朗, 渡邊 亮彦, 宮澤 彬, 五島 圭一, 柳瀬 利彦, 高村 大也, and 宮尾 祐介. 時系列株価データからの市況コメントの自動生成. *自然言語処理*, 27(2):299–328, 2020.
- [27] 田川 裕輝 and 嶋田 和孝. スポーツ要約生成におけるテンプレート型手法とニューラル型手法の提案と比較. *自然言語処理*, 25(4):357–391, 2018.
- [28] Soichiro Murakami, Sora Tanaka, Masatsugu Hangyo, Hidetaka Kamigaito, Kotaro Funakoshi, Hiroya Takamura, and Manabu Okumura. Generating weather comments from meteorological simulations. In *Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume*, pages 1462–1473, Online, April 2021. Association for Computational Linguistics.
- [29] Soichiro Murakami, Akihiko Watanabe, Akira Miyazawa, Keiichi Goshima, Toshihiko Yanase, Hiroya Takamura, and Yusuke Miyao. Learning to generate market comments from stock prices. In *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1374–1384, Vancouver, Canada, July 2017. Association for Computational Linguistics.
- [30] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, undefinedukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Proceedings of the 31st International Conference on Neural Information Processing Systems, NIPS’17*, page 6000–6010, Red Hook, NY, USA, 2017. Curran Associates Inc.
- [31] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers)*, pages 4171–4186, Minneapolis, Minnesota, June 2019. Association for Computational Linguistics.
- [32] Colin Raffel, Noam Shazeer, Adam Roberts, Katherine Lee, Sharan Narang, Michael Matena, Yanqi Zhou, Wei Li, and Peter J. Liu. Exploring the

- limits of transfer learning with a unified text-to-text transformer. *Journal of Machine Learning Research*, 21(140):1–67, 2020.
- [33] Alec Radford, Jeff Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners, 2019.
- [34] Hamza Harkous, Isabel Groves, and Amir Saffari. Have your text and use it too! end-to-end neural data-to-text generation with semantic fidelity. In *Proceedings of the 28th International Conference on Computational Linguistics*, pages 2410–2424, Barcelona, Spain (Online), December 2020. International Committee on Computational Linguistics.
- [35] Mihir Kale and Abhinav Rastogi. Text-to-text pre-training for data-to-text tasks. In *Proceedings of the 13th International Conference on Natural Language Generation*, pages 97–102, Dublin, Ireland, December 2020. Association for Computational Linguistics.
- [36] Joshua Maynez, Shashi Narayan, Bernd Bohnet, and Ryan McDonald. On faithfulness and factuality in abstractive summarization. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*, pages 1906–1919, Online, July 2020. Association for Computational Linguistics.
- [37] Sam Wiseman, Stuart Shieber, and Alexander Rush. Challenges in data-to-document generation. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, pages 2253–2263, Copenhagen, Denmark, September 2017. Association for Computational Linguistics.
- [38] Bhuwan Dhingra, Manaal Faruqui, Ankur P. Parikh, Ming-Wei Chang, Dipanjan Das, and William W. Cohen. Handling divergent reference texts when evaluating table-to-text generation. In Anna Korhonen, David R. Traum, and Lluís Màrquez, editors, *Proceedings of the 57th Conference of the Association for Computational Linguistics, ACL 2019, Florence, Italy, July 28-August 2, 2019, Volume 1: Long Papers*, pages 4884–4895. Association for Computational Linguistics, 2019.
- [39] Tom Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared D Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, Sandhini Agarwal, Ariel Herbert-Voss, Gretchen Krueger,

Tom Henighan, Rewon Child, Aditya Ramesh, Daniel Ziegler, Jeffrey Wu, Clemens Winter, Chris Hesse, Mark Chen, Eric Sigler, Mateusz Litwin, Scott Gray, Benjamin Chess, Jack Clark, Christopher Berner, Sam McCandlish, Alec Radford, Ilya Sutskever, and Dario Amodei. Language models are few-shot learners. In H. Larochelle, M. Ranzato, R. Hadsell, M.F. Balcan, and H. Lin, editors, *Advances in Neural Information Processing Systems*, volume 33, pages 1877–1901. Curran Associates, Inc., 2020.

[40] Aakanksha Chowdhery, Sharan Narang, Jacob Devlin, Maarten Bosma, Gaurav Mishra, Adam Roberts, Paul Barham, Hyung Won Chung, Charles Sutton, Sebastian Gehrmann, Parker Schuh, Kensen Shi, Sasha Tsvyashchenko, Joshua Maynez, Abhishek Rao, Parker Barnes, Yi Tay, Noam Shazeer, Vinodkumar Prabhakaran, Emily Reif, Nan Du, Ben Hutchinson, Reiner Pope, James Bradbury, Jacob Austin, Michael Isard, Guy Gur-Ari, Pengcheng Yin, Toju Duke, Anselm Levskaya, Sanjay Ghemawat, Sunipa Dev, Henryk Michalewski, Xavier Garcia, Vedant Misra, Kevin Robinson, Liam Fedus, Denny Zhou, Daphne Ippolito, David Luan, Hyeontaek Lim, Barret Zoph, Alexander Spiridonov, Ryan Sepassi, David Dohan, Shivani Agrawal, Mark Omernick, Andrew M. Dai, Thanumalayan Sankaranarayanan Pillai, Marie Pellat, Aitor Lewkowycz, Erica Moreira, Rewon Child, Oleksandr Polozov, Katherine Lee, Zongwei Zhou, Xuezhi Wang, Brennan Saeta, Mark Diaz, Orhan Firat, Michele Catasta, Jason Wei, Kathy Meier-Hellstern, Douglas Eck, Jeff Dean, Slav Petrov, and Noah Fiedel. Palm: Scaling language modeling with pathways, 2022.

[41] OpenAI. Gpt-4 technical report, 2023.

[42] Rohan Anil, Andrew M. Dai, Orhan Firat, Melvin Johnson, Dmitry Lepikhin, Alexandre Passos, Siamak Shakeri, Emanuel Taropa, Paige Bailey, Zhifeng Chen, Eric Chu, Jonathan H. Clark, Laurent El Shafey, Yanping Huang, Kathy Meier-Hellstern, Gaurav Mishra, Erica Moreira, Mark Omernick, Kevin Robinson, Sebastian Ruder, Yi Tay, Kefan Xiao, Yuanzhong Xu, Yujing Zhang, Gustavo Hernandez Abrego, Junwhan Ahn, Jacob Austin, Paul Barham, Jan Botha, James Bradbury, Siddhartha Brahma, Kevin Brooks, Michele Catasta, Yong Cheng, Colin Cherry, Christopher A. Choquette-Choo, Aakanksha Chowdhery, Clément Crepy, Shachi Dave,

Mostafa Dehghani, Sunipa Dev, Jacob Devlin, Mark Díaz, Nan Du, Ethan Dyer, Vlad Feinberg, Fangxiaoyu Feng, Vlad Fienber, Markus Freitag, Xavier Garcia, Sebastian Gehrmann, Lucas Gonzalez, Guy Gur-Ari, Steven Hand, Hadi Hashemi, Le Hou, Joshua Howland, Andrea Hu, Jeffrey Hui, Jeremy Hurwitz, Michael Isard, Abe Ittycheriah, Matthew Jagielski, Wenhao Jia, Kathleen Kenealy, Maxim Krikun, Sneha Kudugunta, Chang Lan, Katherine Lee, Benjamin Lee, Eric Li, Music Li, Wei Li, YaGuang Li, Jian Li, Hyeontaek Lim, Hanzhao Lin, Zhongtao Liu, Frederick Liu, Marcello Maggioni, Aroma Mahendru, Joshua Maynez, Vedant Misra, Maysam Mousaleem, Zachary Nado, John Nham, Eric Ni, Andrew Nystrom, Alicia Parrish, Marie Pellat, Martin Polacek, Alex Polozov, Reiner Pope, Siyuan Qiao, Emily Reif, Bryan Richter, Parker Riley, Alex Castro Ros, Aurko Roy, Brennan Saeta, Rajkumar Samuel, Renee Shelby, Ambrose Slone, Daniel Smilkov, David R. So, Daniel Sohn, Simon Tokumine, Dasha Valter, Vijay Vasudevan, Kiran Vodrahalli, Xuezhi Wang, Pidong Wang, Zirui Wang, Tao Wang, John Wieting, Yuhuai Wu, Kelvin Xu, Yunhan Xu, Linting Xue, Pengcheng Yin, Jiahui Yu, Qiao Zhang, Steven Zheng, Ce Zheng, Weikang Zhou, Denny Zhou, Slav Petrov, and Yonghui Wu. Palm 2 technical report, 2023.

- [43] Jason Wei, Xuezhi Wang, Dale Schuurmans, Maarten Bosma, Brian Ichter, Fei Xia, Ed Chi, Quoc Le, and Denny Zhou. Chain-of-thought prompting elicits reasoning in large language models, 2023.
- [44] Takeshi Kojima, Shixiang Shane Gu, Machel Reid, Yutaka Matsuo, and Yusuke Iwasawa. Large language models are zero-shot reasoners, 2023.
- [45] Shunyu Yao, Jeffrey Zhao, Dian Yu, Nan Du, Izhak Shafran, Karthik Narasimhan, and Yuan Cao. React: Synergizing reasoning and acting in language models, 2023.
- [46] Aman Madaan, Niket Tandon, Prakhar Gupta, Skyler Hallinan, Luyu Gao, Sarah Wiegreffe, Uri Alon, Nouha Dziri, Shrimai Prabhumoye, Yiming Yang, Shashank Gupta, Bodhisattwa Prasad Majumder, Katherine Hermann, Sean Welleck, Amir Yazdanbakhsh, and Peter Clark. Self-refine: Iterative refinement with self-feedback, 2023.
- [47] Ziwei Ji, Nayeon Lee, Rita Frieske, Tiezheng Yu, Dan Su, Yan Xu, Etsuko Ishii, Ye Jin Bang, Andrea Madotto, and Pascale Fung. Survey of hallucination in large language models, 2023.

- nation in natural language generation. *ACM Comput. Surv.*, 55(12), mar 2023.
- [48] 吉村 枝里子, 渡部 広一, and 河岡 司. 知能ロボットにおける挨拶文の自動生成方式. *人工知能学会全国大会論文集*, JSAI04:140–140, 2004.
- [49] 石脇 滉己 and 荒川 達也. 「一見良い手」を含めた初心者向け詰将棋解説文生成の提案. Technical Report 5, 群馬工業高等専門学校専攻科生産システム工学科, 群馬工業高等専門学校電子情報工学科, jun 2015.
- [50] 園田 亜斗夢. アパレル ec サイトにおける説明文自動生成. *経営情報学会 全国研究発表大会要旨集*, 2018t10:125–127, 2018.
- [51] Yevgeniy Puzikov and Iryna Gurevych. E2E NLG challenge: Neural models vs. templates. In *Proceedings of the 11th International Conference on Natural Language Generation*, pages 463–471, Tilburg University, The Netherlands, November 2018. Association for Computational Linguistics.
- [52] 村上聡一郎, 笹野遼平, 高村大也, and 奥村学. 打者成績からのイニング速報の自動生成. In *言語処理学会第 22 回年次大会発表論文集*, pages 338–341, 2016.
- [53] Rong Ye, Wenxian Shi, Hao Zhou, Zhongyu Wei, and Lei Li. Variational template machine for data-to-text generation, 2020.
- [54] F.O. Isinkaye, Y.O. Folajimi, and B.A. Ojokoh. Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, 16(3):261–273, 2015.
- [55] Chris van der Lee, Emiel Kraahmer, and Sander Wubben. PASS: A Dutch data-to-text system for soccer, targeted towards specific audiences. In *Proceedings of the 10th International Conference on Natural Language Generation*, pages 95–104, Santiago de Compostela, Spain, September 2017. Association for Computational Linguistics.
- [56] Saar Hommes, Chris van der Lee, Felix Clouth, Jeroen Vermunt, Xander Verbeek, and Emiel Kraahmer. A personalized data-to-text support tool for cancer patients. In *Proceedings of the 12th International Conference on Natural Language Generation*, pages 443–452, Tokyo, Japan, October–November 2019. Association for Computational Linguistics.

- [57] Qibin Chen, Junyang Lin, Yichang Zhang, Hongxia Yang, Jingren Zhou, and Jie Tang. Towards knowledge-based personalized product description generation in e-commerce. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, KDD '19*, page 3040–3050, New York, NY, USA, 2019. Association for Computing Machinery.
- [58] Xiang Ao, Xiting Wang, Ling Luo, Ying Qiao, Qing He, and Xing Xie. PENS: A dataset and generic framework for personalized news headline generation. In Chengqing Zong, Fei Xia, Wenjie Li, and Roberto Navigli, editors, *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)*, pages 82–92, Online, August 2021. Association for Computational Linguistics.
- [59] Nisan Stiennon, Long Ouyang, Jeff Wu, Daniel M. Ziegler, Ryan Lowe, Chelsea Voss, Alec Radford, Dario Amodei, and Paul Christiano. Learning to summarize from human feedback, 2022.
- [60] Long Ouyang, Jeff Wu, Xu Jiang, Diogo Almeida, Carroll L. Wainwright, Pamela Mishkin, Chong Zhang, Sandhini Agarwal, Katarina Slama, Alex Ray, John Schulman, Jacob Hilton, Fraser Kelton, Luke Miller, Maddie Simens, Amanda Askell, Peter Welinder, Paul Christiano, Jan Leike, and Ryan Lowe. Training language models to follow instructions with human feedback, 2022.
- [61] OpenAI. Chatgpt. <https://chat.openai.com/>, accessed 2023-10-01.
- [62] 寺沢憲吾. 情報学者が競馬予想に踏み出すときに知っておくべきこと. *情報処理*, 60(2):154–158, jan 2019.
- [63] Manish Jogeeah, Akshay Kumar Chandoo, Selukoto Paupiah, and Sameerchand Pudaruth. Using fuzzy logic to predict winners in horseraces at the champ de mars. In *Proceedings of the Third International Conference on Digital Information Processing, E-Business and Cloud Computing, Reduit, Mauritius 2015*, 01 2015.
- [64] 吉田拓海, 横山想一郎, 山下倫央, and 川村秀憲. 競輪予想記事の自動生成に向けた深層学習によるレース結果予測. *SIG-DOCMAS*, 15(1):1–7.

- [65] David A. Harville. Assigning probabilities to the outcomes of multi-entry competitions. *Journal of the American Statistical Association*, 68(342):312–316, 1973.
- [66] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *CoRR*, abs/1412.6980, 2014.
- [67] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 1997.
- [68] Neo Wu, Bradley Green, Xue Ben, and Shawn O’Banion. Deep transformer models for time series forecasting: The influenza prevalence case, 2020.
- [69] 本田 良司, 小笠原 範光, and 小玉 亮. Transformer による時系列予測. **人工知能学会全国大会論文集**, JSAI2020:1N4GS1301–1N4GS1301, 2020.
- [70] Nicolas Carion, Francisco Massa, Gabriel Synnaeve, Nicolas Usunier, Alexander Kirillov, and Sergey Zagoruyko. End-to-end object detection with transformers. In Andrea Vedaldi, Horst Bischof, Thomas Brox, and Jan-Michael Frahm, editors, *Computer Vision - ECCV 2020 - 16th European Conference, Glasgow, UK, August 23-28, 2020, Proceedings, Part I*, volume 12346 of *Lecture Notes in Computer Science*, pages 213–229. Springer, 2020.
- [71] Liyuan Liu, Haoming Jiang, Pengcheng He, Weizhu Chen, Xiaodong Liu, Jianfeng Gao, and Jiawei Han. On the variance of the adaptive learning rate and beyond, 2020.
- [72] J. Weston Hughes, Keng-hao Chang, and Ruofei Zhang. Generating better search engine text advertisements with deep reinforcement learning. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, KDD ’19*, page 2269–2277, New York, NY, USA, 2019. Association for Computing Machinery.
- [73] オッズ・パーク株式会社. 競輪 (keirin・ケイリン) ならオッズパーク競輪 | 予想情報も充実! <http://www.oddsark.com/keirin/>, Accessed on 05/29/2018.
- [74] 株式会社チャリ・ロト. チャリロト.com | 競輪・オートの子券・くじ購入のオフィシャルサイト. <https://www.chariloto.com/>, accessed 2019-06-17.
- [75] Taku Kudo, Kaoru Yamamoto, and Yuji Matsumoto. Applying conditional random fields to Japanese morphological analysis. In *Proceedings of the 2004*

Conference on Empirical Methods in Natural Language Processing, pages 230–237, Barcelona, Spain, July 2004. Association for Computational Linguistics.

- [76] Sato Toshinori. Neologism dictionary based on the language resources on the web for mecab, 2015.
- [77] Hamza Harkous, Isabel Groves, and Amir Saffari. Have your text and use it too! end-to-end neural data-to-text generation with semantic fidelity. In *Proceedings of the 28th International Conference on Computational Linguistics*, pages 2410–2424, Barcelona, Spain (Online), December 2020. International Committee on Computational Linguistics.
- [78] 日本ベンダーネット株式会社. 競輪 (keirin・ケイリン) 情報なら競輪ステーション. <https://keirin-station.com/>, accessed 2023-10-01.

研究業績

査読付学会誌等

1. 吉田 拓海, 横山 想一郎, 山下 倫央, 川村 秀憲 : 「競輪におけるテキスト情報生成のためのレース結果予測」, 情報処理学会論文誌, Vol.60, No.10, pp.1641-1652 (2019)
2. 吉田 拓海, 横山 想一郎, 山下 倫央, 川村 秀憲 : 「競輪におけるテキスト情報の自動生成システムの開発」, 電子情報通信学会論文誌 D, Vol.J105-D, No.1, pp.60-74 (2022)

査読付国際会議プロシーディング

1. Takumi Yoshida, Soichiro Yokoyama, Tomohisa Yamashita, Hidenori Kawamura : “Prediction of Race Results and Generation of Predicted Articles in Keirin”, The 22nd Asia Pacific Symposium on Intelligent and Evolutionary Systems, Sapporo, Japan, December 20-22, pp.99-105 (2018)
2. Takumi Yoshida, Soichiro Yokoyama, Tomohisa Yamashita, Hidenori Kawamura : “Text Generation with Personalization Features for Information Presentation in Decision Support”, 2024 13th International Conference on Software and Computer Applications, Bali Island, Indonesia, February 1-3 (2024) (採録決定済み)