

卒業論文

タイトルはここ

english title

富山県立大学大学院 工学研究科 電子・情報工学専攻

2355020 水上和秀

指導教員 António Oliveira Nzinga René 講師

提出年月:

目次

図一覧	ii
表一覧	iii
記号一覧	iv
第1章 はじめに	1
§ 1.1 本研究の背景	1
§ 1.2 本研究の目的	1
§ 1.3 本論文の概要	2
第2章 関連研究	3
§ 2.1 SNS の普及による消費行動の変化と口コミの役割	3
§ 2.2 自然言語処理による感情分析に関する研究例	3
§ 2.3 未定、(トピックモデル、文章クラスタリングのについて?)	3
第3章 理論の説明	3
§ 3.1 BERT による文章のベクトル化と感情分析	3
§ 3.2 SHAP による予測モデルの解釈	6
§ 3.3 文章クラスタリングの概要	6
第4章 提案手法	7
§ 4.1 テキストマイニングによるレビューの取得 (レビューの前処理)	7
§ 4.2	7
§ 4.3 提案システムの概要	7
第5章 数値実験並びに考察	9
§ 5.1 数値実験の概要	9
§ 5.2 実験結果と考察	9
第6章 おわりに	10
謝辞	11
参考文献	12

図一覧

3.1	BERT の流れ	4
3.2	何かを載せる予定	4

表一覽

記号一覧

以下に本論文において用いられる用語と記号の対応表を示す.

用語	記号
j 人目の使用者の名前	ϵ_j
j 人目の身長	α_j
j 人目の体重	β_j
j 人目の基礎代謝量 (下限)	B_j^L
j 人目基礎代謝量 (上限)	B_j^H
j 人目のアレルギー情報	x_j
j 人の有する生活習慣病	z_j
対象の日数	D
レシピの数	R
食材の数	Q
栄養素の数	N
データベース上の食材数	S
データベース上の食材番号	$d : 1, 2, 3, \dots, S$
日の番号	$k : 1, 2, 3, \dots, 3D$
栄養素の番号	$l : 1, 2, 3, \dots, N$
材料の番号	$m : 1, 2, 3, \dots, Q$
レシピの番号	$i : 1, 2, 3, \dots, R$
i 番目のレシピの名前	y_i
i 番目のレシピの献立フラグ	r_{ki}
i 番目のレシピの主菜フラグ	σ_i
i 番目のレシピの調理時間	T_i
i 番目のレシピの摂取カロリー	C_i
i 番目のレシピの調理コスト	G_i
i 番目のレシピの m 番目の材料の名前	q_{im}
i 番目のレシピの m 番目の材料量	e_{im}
i 番目のレシピの l 番目の栄養素の名前	n_{il}
i 番目のレシピの l 番目の栄養素の量	f_{il}
d 番目の食材名	Z_d
d 番目の食材の販売単位	W_d
d 番目の食材の値段	M_d

はじめに

§ 1.1 本研究の背景

近年、インターネットの普及により、個人がインターネット上に情報を発信する機会が急増している。特にSNSやwebサイトでは、商品やサービスに対する個人の意見や感想が日常的に共有されており、これらの投稿は、いわゆる「口コミ」として他の消費者の意思決定に大きな影響を与えるようになっている。

現代の消費行動の特徴として、総務省の「情報通信白書」の概要によると、年代に関わらず8割以上の利用者が、レビューによって購入する商品を決めた経験があると回答しており、この傾向は若年層だけでなく中高年層にも広がっていることが示されている。

さらに、レビューは商品の品質やサービスの満足度を評価するだけでなく、購入前の不安を解消する役割も担っている。例えば、「他の利用者也満足している」「多くの人が推奨している」といったレビューが、購入の後押しとなるケースが多い。一方で、ネガティブなレビューが購入の抑止要因となる場合もあり、レビュー内容のポジティブ・ネガティブの傾向が購入意思決定に直結することも明らかになっている。このことから、口コミやレビューは、単なる参考情報ではなく、現代の消費者行動において重要な役割を果たしているといえる。また、このような消費者の意見は、企業にとっても貴重な情報源であり、企業は口コミを分析することで、消費者のニーズや改善すべきポイントを把握し、製品開発やマーケティング戦略の最適化を図っている。最近では、

- ・企業でのマーケットの例
- ・このように、レビューを分析することは有効である

§ 1.2 本研究の目的

口コミの内容は、多様な観点から構成される。たとえば、飲食店の口コミであれば「味」「価格」「サービス」「雰囲気」といった複数の要素が含まれることが一般的である。しかし、これらの要素が単一の文章内で複雑に絡み合って記述されることが多く、従来の方法では口コミ全体を的確に理解することが難しいという課題がある。

また、日々投稿される口コミの数は膨大であり、情報量が非常に多いため、データの抽出や性差が難し(口コミ分析の課題、自然言語処理の課題を書く)

そこで本研究では、口コミを詳細に分析するシステムを作成する。本システムはシステム

を利用するユーザ BERT で口コミの感情分析を行い、分析結果に大きく影響を及ぼしている単語を SHAP で可視化を行う。また、トピックごとにクラスタリングを行うことでユーザにとってより解釈可能な口コミの分析を行うシステムを提案する。

- ・口コミの分析・システムの簡単な流れを書く
- ・検証方法についても書く

§ 1.3 本論文の概要

本論文は次のように構成される。

第 1 章 本研究の背景と目的について説明する。背景ではを述べる。目的ではを述べる。

第 2 章 関連研究について述べる。

第 3 章

第 4 章

第 5 章

第 6 章 本研究で述べている提案手法をまとめて説明する。また、今後の課題について述べる。

関連研究

- § 2.1 SNSの普及による消費行動の変化と口コミの役割
- § 2.2 自然言語処理による感情分析に関する研究例
- § 2.3 未定、(トピックモデル、文章クラスタリングのについて?)

理論の説明

§ 3.1 BERT による文章のベクトル化と感情分析

BERT の技術的説明を書く。

BERT

BERT は、Google が提案した自然言語処理モデルの一つであり、Transformer の Encoder 部分を基盤とし、Attention メカニズムを用いて単語間の関係性をモデル化している。

BERT による処理の流れを図??に示す。持っていることが最大の特徴であり、文脈を考慮して単語の意味を理解することができる。また、BERT は、テキスト内の単語の位置情報を学習することができるため、単語の順序を考慮した文脈理解が可能である。これにより、文書分類、質問応答、言語翻訳など、様々な自然言語処理タスクに応用されている。BERT は、大規模なコーパスから事前に学習されたモデルであり、学習済みのモデルを転移学習することで、より小規模なデータセットでも高い精度で処理することができる。

結果として、多くの NLP タスクで従来手法を上回る精度を達成しており、BERT は分散表現と転移学習において大きな進展をもたらした。

Transformer

近年、翻訳などの入力文章を別の文章で出力するというモデルは、Attention を用いたエンコーダー、デコーダ形式の RNN が主流であった。しかし RNN は逐次的に単語を処理しているため、訓練時に並列処理ができないという欠点があった。それに対し Transformer は、RNN や CNN を用いず Attention のみを用いている。Transformer は、再帰も畳み込みも一切行わないので並列化が容易であり、他のタスクにも汎用性が高いという特徴がある。Transformer においては Attention を多数並列に配置した Multi-Head Attention が用いられる。

Attention

Attention は、入力の各トークンが他のすべてのトークンにどれだけ関連しているかを学習するメカニズムであり、この機構は、一般的に自己注意（Self-Attention）として知られている。Self-Attention では、各トークンの埋め込みベクトルを Query、Key、および Value という 3 つのベクトルに変換し、その相関関係を計算して、重み付けされた値を集約する。

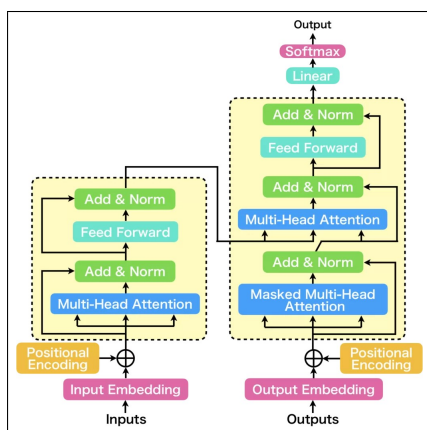


図 3.1: BERT の流れ




図 3.2: 何かを載せる予定

Query、Key、および Value は入力単語 x_i にそれぞれの重み W_Q 、 W_K 、 W_V を用いて以下の式で定式化される。

$$Q_i = W_Q \cdot x_i, \quad K_i = W_K \cdot x_i, \quad V_i = W_V \cdot x_i \quad (3.1)$$

また、3つの相関関係は各トークンのクエリとキーとの内積を計算することで求めることができる。

$$\text{score}(Q_i, K_j) = \frac{Q_i K_j^T}{\sqrt{d_k}} \quad (3.2)$$

ここで、 d_k は Query と key の次元数である。得られた式にソフトマックス関数を適応し、 V_i を付加重することによって Attention を求めることができる。

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (3.3)$$

Multi-Head Attention

Attention は一つの計算を逐次的に行っているため、1つの視点からしか文脈を読み取ることができない。これに対し、Multi-Head Attention は複数の Attention を並列に連結した構造をしているため、各ヘッドが独自の視点から情報を捉え、最終的にそれらを結合して出力を得ます。このアプローチにより、情報の多様な側面を同時に捉えることができる。Multi-Head Attention は以下の式で定式化される。

$$\text{Multi-HeadAttention}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W_o \quad (3.4)$$

$$\text{where } \text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (3.5)$$

<Attention への入力方法>

Single-head Attention は、ある単語に対して、その単語が文章に含まれる単語とどれだけ類似しているのかを計算し、それらを確率的に表現したものである。Transformer における Attention の入力には主に以下の2種類の入力方法が用いられている。

1. Self-Attention (softmax に与える Query, Key, Value を同じ値にする)
2. SourceTarget-Attention (Key, Value を同じ値にし, Query を異なる値にする)

Single-Head Attention では多種多様な意味や文法をもつ単語に対しても単一の注意表現が生成される。そこで、Single-Head Attention を多数並列に配置して Multi-Head にすることで、複数の特徴部分空間における注意表現の獲得をすることができる。

以上のことから、文章を行列で表せることが分かった。しかし、multi-head Attention は入力の順序に関する情報を持たないため、文章を正しく扱えなくなる可能性がある。そのため、Embedding 層からの行列に位置情報を含んだ行列を足し合わせることで、文字の順番の概念を扱えるようにする必要がある。これを可能にするのが Positional Encoding である。 pos をトークンの位置、 i をエンコーディングベクトルの次元のインデックス、 d をエンコーディングの次元数とすると以下の式で定式化できる

Positional Encoding

$$PE_{(pos, 2i)} = \sin \left(\frac{pos}{10000^{\frac{2i}{d_{model}}}} \right) \quad (3.6)$$

$$PE_{(pos, 2i+1)} = \cos \left(\frac{pos}{10000^{\frac{2i}{d_{model}}}} \right) \quad (3.7)$$

入力文章の単語数が 50 個まで扱え、Embedding 層の埋め込み次元数が 128 次元の場合、Positional Encoding が生成する行列は 128 次元の行ベクトルが縦に 50 個並んだ行列になる。この行列は、各行のベクトルが絶対に同じものにならないため、この行列から単語の位置情報を表すことができる。具体的には、行ベクトルの各次元は、単語の位置情報に応じて、異なる値が割り当てられている。例えば、最初の行ベクトルの最初の次元は、単語の位置が 0 であることを示し、最後の行のベクトルは、単語の位置が 49 であることを示す。このように、Positional Encoding は、単語の位置情報を行ベクトルに埋め込むことで、Transformer モデルが単語の順序情報を利用できるようにしている。

モデルの学習方法

● 事前学習

事前学習では、BERT は Masked Language Modeling (MLM) と Next Sentence Prediction (NSP) という 2 つのタスクを使ってモデルを訓練する。MLM では、入力文の中でランダムに選ばれた単語を「[MASK]」トークンで置き換え、モデルにその単語を予測させる。MLM において、Multi-Head Attention は文脈を双方向的に考慮し、マスクされた単語を予測する。Multi-Head Attention は、文全体の意味的および構文的な関係を理解し、正しい予測を行うための情報を集約する。

● ファインチューニング

ファインチューニングをする

§ 3.2 SHAP による予測モデルの解釈

shap の技術的説明を書く

SHAP

$\mathbf{X} = (X_1, \dots, X_J)$ を説明変数とする学習済みのモデルを $\hat{f}(\mathbf{X})$ とする．インスタンス i の説明変数が $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,J})$ とすると，インスタンス i の予測値は $\hat{f}(\mathbf{x}_i)$ である．ここで，予測の期待値を $\mathbb{E}[\hat{f}(\mathbf{X})]$ ，インスタンス i の説明変数 $x_{i,j}$ の貢献度 $\phi_{i,j}$ としたとき，

$$\hat{f}(\mathbf{x}_i) - \mathbb{E}[\hat{f}(\mathbf{X})] = \sum_{j=1}^J \phi_{i,j} \quad (3.8)$$

のように，期待値からの差分を貢献度の総和で表現できるように，貢献度を分解することが，SHAP の基本的な考え方である．線形モデルであれば，比較的容易に分解することができるが，非線形モデルではこのままでは難しい．そのため，SHAP では，協力ゲーム理論の Shapley 値の考え方をを用いて，貢献度を分解する．

ここで，協力ゲーム理論のひとつであるアルバイトゲームを説明する．アルバイトの参加者として，A, B, C の3つのプレイヤーを仮定し，アルバイトの参加者とそのときに得られる報酬には，表??のような関係があるとする．

A・B・C の3プレイヤーが参加したときの報酬は24である．より貢献度が大きいプレイヤーに，より多くの報酬を配分するとすれば，その貢献度はどのように算出すべきだろうか．ここで，限界貢献度という概念を導入する．限界貢献度とは，あるプレイヤーが参加したときの報酬と，参加する直前の報酬との差を表す．例えば，B・Cがすでに参加しているときにAが参加した場合の限界貢献度は， $24 - 10 = 14$ である．しかし，各プレイヤーがどのような順序で参加するかにより，限界貢献度は異なる．例えば，Aの限界貢献度について，A, B, C という順番で参加したときは6であるが，B, C, A という順序で参加したときは14である．

この影響を解消するため，考えられるすべての順序で限界貢献度を算出し，その平均を求めることにする．例えば，Aの限界貢献度の平均値は， $(6 + 6 + 16 + 14 + 13 + 14)/6 = 11.5$ である．この限界貢献度の平均値を Shapley 値といい，これをもとに報酬を分配する．一般に， J つのプレイヤーが存在するとき，プレイヤー j の Shapley 値 ϕ_j は以下のように算出される．

$$\phi_j = \frac{1}{|\mathcal{J}|!} \sum_{\mathcal{S} \subseteq \mathcal{J} \setminus \{j\}} (|\mathcal{S}|!(|\mathcal{J}| - |\mathcal{S}| - 1)!)(v(\mathcal{S} \cup \{j\}) - v(\mathcal{S})) \quad (3.9)$$

SHAP は，この Shapley 値の考え方を機械学習のモデルに適用している．例えば，説明変数が X_1, X_2 であるモデルにおいて，インスタンス i の予測値 $v(\{1, 2\})$ の，説明変数を $x_{i,1}, x_{i,2}$ とすると，

$$v(\{1, 2\}) = \hat{f}(x_{i,1}, x_{i,2}) \quad (3.10)$$

である。また、 $x_{i,1}$ と $x_{i,2}$ のいずれも未知の場合は、予測値の期待値とし、

$$v(\emptyset) = \mathbb{E} \left[\hat{f}(X_1, X_2) \right] \quad (3.11)$$

である。では、 $x_{i,1}$ は既知であり、 $x_{i,2}$ は不明であるときの予測値 $v(\{1\})$ は、後者について周辺化を行い、

$$v(\{1\}) = \mathbb{E} \left[\hat{f}(x_{i,1}, X_2) \right] = \int \hat{f}(x_{i,1}, x_2) p(x_2) dx_2 \quad (3.12)$$

である。よって、 $x_{i,1}$, $x_{i,2}$ という順序で説明変数が判明したときの、それぞれ時点における限界貢献値 $\Delta_{i,1}$, $\Delta_{i,2}$ は、

$$\Delta_{i,1} = \mathbb{E} \left[\hat{f}(x_{i,1}, X_2) \right] - \mathbb{E} \left[\hat{f}(X_1, X_2) \right] \quad (3.13)$$

$$\Delta_{i,2} = \mathbb{E} \left[\hat{f}(x_{i,1}, x_{i,2}) \right] - \mathbb{E} \left[\hat{f}(x_{i,1}, X_2) \right] \quad (3.14)$$

である。Shapley 値と同様に、考え得るすべての順番で算出し、それらを平均する。すなわち、説明変数 $x_{i,1}, x_{i,2}$ について、その平均値 $\phi_{i,1}, \phi_{i,2}$ は、

$$\phi_{i,1} = \frac{1}{2} \left(\left(\mathbb{E} \left[\hat{f}(x_{i,1}, X_2) \right] - \mathbb{E} \left[\hat{f}(X_1, X_2) \right] \right) + \left(\hat{f}(x_{i,1}, x_{i,2}) - \mathbb{E} \left[\hat{f}(X_1, x_{i,2}) \right] \right) \right) \quad (3.15)$$

$$\phi_{i,2} = \frac{1}{2} \left(\left(\hat{f}(x_{i,1}, x_{i,2}) - \mathbb{E} \left[\hat{f}(x_{i,1}, X_2) \right] \right) + \left(\mathbb{E} \left[\hat{f}(X_1, x_{i,2}) \right] - \mathbb{E} \left[\hat{f}(X_2, X_2) \right] \right) \right) \quad (3.16)$$

である。このとき、 $\phi_{i,1}, \phi_{i,2}$ は、協力ゲーム理論においては Shapley 値と呼ぶが、SHAP においては SHAP 値と呼ぶ。式 3.17 と式 3.18 より、 $\phi_{i,1}$ と $\phi_{i,2}$ を足すと、

$$\phi_{i,1} + \phi_{i,2} = \hat{f}(x_{i,1} + x_{i,2}) - \mathbb{E} \left[\hat{f}(X_1, X_2) \right] \quad (3.17)$$

であり、式 3.10 と同様に、インスタンス i の予測値と、予測の期待値との差分になっていることが分かる。

ゲーム理論とシャープレイ値について書く

シャープレイ値と shap の関係について書く

§ 3.3 文章クラスタリングの概要

クラスタリング手法と流れについて説明する

提案手法

§ 4.1 テキストマイニングによるレビューの取得 (レビューの前処理)

§ 4.2

§ 4.3 提案システムの概要

数値実験並びに考察

§ 5.1 数値実験の概要

§ 5.2 実験結果と考察

おわりに

謝辞

本研究を遂行するにあたり，多大なご指導と終始懇切丁寧なご鞭撻を賜った富山県立大学工学部電子・情報工学科情報基盤工学講座の António Oliveira Nzinga René 講師，奥原浩之教授に深甚な謝意を表します．最後になりましたが，多大な協力をしていただいた研究室の同輩諸氏に感謝致します．

2025 年 2 月

水上和秀

参考文献

- [1] 公益社団法人 千葉県栄養士会, “生活習慣病の予防、食生活 生活習慣病の予防と食事”, <https://www.eiyou-chiba.or.jp/commons/shokuji-kou/preventive/seikatusyukan/>, 閲覧日 2023.1.7.
- [2] 国立研究開発法人 国立循環器病研究センター, “食事療法について”, <https://www.ncvc.go.jp/hospital/pub/knowledge/diet/diet02/>, 閲覧日 2023.1.7
- [3] ソフトム株式会社, “ソフトム通信 第 79 号「給食業界における A I 活用」”, https://data.nifcloud.com/blog/food-service-provider_ai-use-case_01/, 閲覧日 2022.12.28.
- [4] 貝沼やす子, 江間章子, “日常の献立作りの実態に関する調査研究 (第 1 報)”, 日本調理学会誌, Vol.30, No. 4, pp. 364-371, 1997.
- [5] 株式会社おいしい健康, “おいしい健康”, <https://oishi-kenko.com/>, 閲覧日 2022.10.16.
- [6] 総務省統計局, “小売り物価統計調査による価格調査”, <https://jpmarket-conditions.com/>, 閲覧日 2022.10.11.
- [7] J. W. Ratcliff and D. Metzener, “Pattern Matching: The Gestalt Approach”, *Dr. Dobb's Journal*, p.46, 1988.
- [8] C. A. Coello Coello and M. S. Lechuga, “MOPSO: a proposal for multiple objective particle swarm optimization, ” *Proceedings of the 2002 Congress on Evolutionary Computation (CEC'02)*, Vol. 2, pp. 1051-1056, 2002.
- [9] Q. Zhang and H. Li, “MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition”, *IEEE Trans. Evolutionary Computation*, Vol. 11, No. 6, pp. 712-731, 2007.
- [10] LeftLetter, “多目的進化型アルゴリズム MOEA/D とその改良手法”, <https://qiita.com/LeftLetter/items/a10d5c7e133cc0a679fa>, 閲覧日 2023.1.6.
- [11] J. H. Holland, “Adaptation in Natural and Artificial Systems”, 1975.
- [12] K. Deb, A. Pratap, S. Agarwal and T. Meyarivan, “A Fast and Elitist Multi-objective Genetic Algorithm: NSGA-II”, *IEEE Tran. on Evolutionary Computation*, Vol. 6, No. 2, pp. 182-197, 2002.
- [13] D. E. Goldberg, “Genetic algorithms in search, optimization and machine learning ”, *Addison-Wesly*, 1989.
- [14] メディカル・ケア・サービス株式会社, “制限食にはどんな種類があるの?”, 健達ネット, <https://www.mcsg.co.jp/kentatsu/health-care/12106>, 閲覧日 2023.1.6.

- [15] ときわ会栄養指導課, “減塩について”, 栄養指導,
<http://www.tokiwa.or.jp/nutrition/diet/low-salt.html>, 閲覧日 2023.01.15
- [16] 全国健康保険協会, “ちょっとした工夫で脂質をコントロール”,
<https://www.kyoukaikenpo.or.jp/g4/cat450/sb4501/p004/>, 閲覧日 2023.01.15
- [17] 厚生労働省, “日本人の食事摂取基準 (2020 年度版)”,
<https://www.mhlw.go.jp/content/10904750/000586559.pdf>, 閲覧日 2023.01.15
- [18] 東京医科大学病院, “カリウムは調理のくふうで減らせます”, 内臓内科,
<https://articles.oishi-kenko.com/syokujinokihon/dialysis/05/>, 閲覧日 2023.01.15
- [19] 厚生労働省, “糖尿病”, <https://www.mhlw.go.jp/content/10904750/000586592.pdf>,
閲覧日 2023.01.17
- [20] 厚生労働省, “慢性腎臓病”, <https://www.mhlw.go.jp/content/10904750/000586595.pdf>,
閲覧日 2023.01.17
- [21] 腎臓内科, “慢性腎臓病の食事療法”, 東京女子医科大学,
<https://www.twmu.ac.jp/NEP/shokujiryohou.html>, 閲覧日 2023.01.17
- [22] 厚生労働省, “脂質異常症”, <https://www.mhlw.go.jp/content/10904750/000586590.pdf>,
閲覧日 2023.01.17
- [23] 厚生労働省, “高血圧”, <https://www.mhlw.go.jp/content/10904750/000586583.pdf>,
閲覧日 2023.01.17
- [24] 厚生労働省, “食べ物アレルギー”, アレルギーポータル,
<https://allergyportal.jp/knowledge/food/>, 閲覧日 2023.01.17
- [25] J. Blank, “pymoo: Multi-objective Optimization in Python ”,
<https://www.egr.msu.edu/kdeb/papers/c2020001.pdf>, 閲覧日 2023.1.22.
- [26] 和正敏, “多目的線形計画問題に対する対話型ファジィ意思決定手法とその応用”, 電子情報通信学会論文誌 Vol. J 65-A, No. 11, pp. 1182-1189, 1982.
- [27] 厚生労働省, “日本人の食事摂取基準 (2020 年版) ”,
<https://www.mhlw.go.jp/content/10904750/000586553.pdf>, 閲覧日 2022.12.26.
- [28] 農林水産省, “一日に必要なエネルギー量と摂取の目安”,
https://www.maff.go.jp/j/syokuiku/zissen_navi/balance/required.html, 閲覧日
2023.1.22.