

日々の行動データを用いた時間割引率の推定

山本 修平¹ 富永 登夢¹ 倉島 健¹ 戸田 浩之¹ 西岡 秀一¹

概要：人間の性格を定量的に指標化することは、人間理解のための重要な取り組みの一つである。時間割引率は経済学の中で扱われる性格指標の一つであり、「待つことをどれだけ嫌がるか」という人間の性質に着目した指標である。時間割引率は肥満率、喫煙率といったネガティブな生活習慣と相関があることが知られており、個人の時間割引率を明らかにすることで、自身や他者が「待つこと」の我慢強さを定量的に理解でき、意思決定の効果的な介入支援も可能になると考えられる。本論文では、ウェアラブルデバイスで観測可能な日々の細かな行動に着目し、行動データを用いた時間割引率推定手法を提案する。行動データから、行動の生起時刻、行動間の遷移特徴、またそれらの差異に関する特徴を抽出し、時間割引率との相関分析によって有効な特徴を獲得することで重回帰モデルを構築する。評価実験では、深層学習をベースとした多量の学習パラメータを要するモデルに比べ、適切な行動特徴を用いた提案手法が時間割引率を高精度に推定できることを示した。

Estimating Time Discounting Rate using Daily Behavior Data

SHUHEI YAMAMOTO¹ TOMU TOMINAGA¹ TAKESHI KURASHIMA¹ HIROYUKI TODA¹
SHUICHI NISHIOKA¹

1. はじめに

人間の性格を定量的な数値によって指標化することは、人間理解のための重要な取り組みの一つである [15]。経済学では伝統的に、人間の性格を時間割引、危険回避、互酬性という3種類の指標として扱う [1]。この内、時間割引とは人間がある報酬を受け取る時、その価値を現在からの時間経過にしたがい割引く性質に着目したものである [24]。時間割引は減衰関数（指数関数や双極関数など）で表現され、その減衰の程度は時間割引率と呼ばれる個人が持つパラメータによって調整される [9]。例えば指数関数で価値の時間割引がされる場合、その関数は $f(t) = \exp(-tk)$ などの形で表現され、このとき t は時間、 k は時間割引率である [18]。指数割引にしたがい、単位時間を日としたとき、100日後に貰う10,000円は、 $k = 0.01$ な人は $10,000 \cdot \exp(-0.01 \cdot 100) \approx 3,679$ 円、 $k = 0.05$ な人は約67円、 $k = 0.10$ な人はほとんど0円に感じる。すなわち、時間割引率の高さは「待つこと」の態度を評価する指標である。時間割引率は行動経済学を中心に人間の生活習慣

と合わせたマクロ調査がされており、時間割引率は肥満率や喫煙率などと相関があることが知られている [16], [28]。これは、高い時間割引率を持つ人間は、将来手に入る満足に比べ、すぐに手に入る目先の満足を優先する傾向があるためである。肥満を例にとると、高い時間割引率を持つ人間は、将来の健康な生活をするための満足よりも、目の前にあるケーキを食べるための満足を優先してしまい、結果として肥満になる。個人の時間割引率を明らかにすることで、「待つこと」に対してどのような態度を持っているかを、自身や他者が定量的に理解でき、それを踏まえた意思決定の支援や自制も可能になると考えられる [3], [20]。

時間割引率の測定は、アンケートの回答結果から算出する方法が一般的である [12], [31]。アンケートは目先の小さな満足（即時報酬）と、将来の大きな満足（遅延報酬）を比較し、回答者にどちらが良いかを選択してもらうものである。例えば、即時報酬として今日の1,000円、遅延報酬として1ヶ月後の10,000円を提示し、どちらを受け取るかを比較すれば、多くの人間が1ヶ月後の10,000円を選ぶと予想される。しかし、今日の1,000円と1ヶ月後の1,100円では、1ヶ月後に100円多く受け取ることができるとし

¹ 日本電信電話株式会社 NTT 人間情報研究所

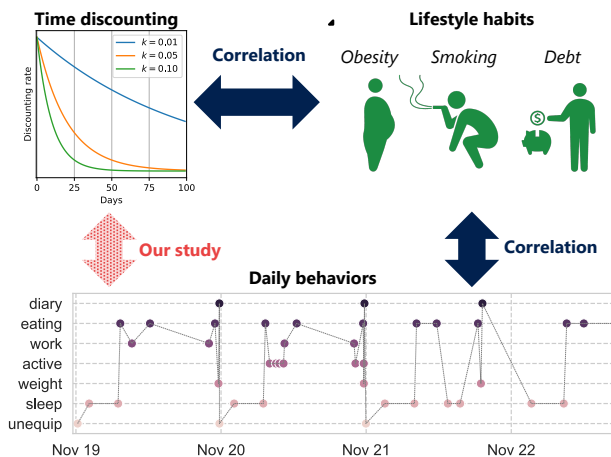


図 1 本研究の位置付け。時間割引率と生活習慣の関係、及び生活習慣と日々の行動の関係は明らかにされている。本研究では、時間割引率と日々の行動の関係を分析し、その分析結果に基づいて時間割引率を推定することに取り組む。

でも、今日の 1,000 円を選ぶ人もいる。このように、報酬を受け取る時間と金額を段階的に変化させた設問を複数用意し、個々人の好みについて即時報酬と遅延報酬が切り替わる点を検出し、そのときの年利に基づいて時間割引率が算出される。

一方で、アンケートの結果から時間割引率を測定することは容易ではない。既存のマクロ調査では、約 40% の人々の時間割引率に関するアンケートが無効回答扱いになっている [14], [16], [42]。これは、時間割引率に関するアンケートは人々にとって馴染みがなく、時間や金額を比較するのに多大な労力を要するため、回答結果中に即時報酬と遅延報酬の好み切り替わる点が複数存在し、無効回答となるケースが多いためであると考えられる。アンケートの回答方法を丁寧に説明したり、有効回答になったときの対価を設定すれば無効回答となるケースを少なくできる可能性もあるが、その分多くの回答を得るための実験コストも大きくなる。また、時間割引率は結婚や住宅の購入など人生に影響のある大きな出来事や、景気や税制など社会環境の変化、感染症や地震といった外乱によって変化するという報告もある [5], [6], [21]。以上のことから、大規模な人間に対して定期的に時間割引率を測定可能な、簡易かつ精度の高い測定方法が必要である。

そこで、本論文ではウェアラブルデバイスから観測可能な日々の行動データから、時間割引率の自動推定に取り組む。我々は、時間割引率、生活習慣、及び日々の細かな行動（睡眠、運動、食事など）の關係に着目した。前述したように、時間割引率と生活習慣（肥満、喫煙など）に關係があることは明らかにされている。また、生活習慣と日々の行動も關係があることが知られており、例えば肥満は、不規則な食事 [30] や運動量の低下 [37] の結果として表出する。以上の先行研究の知見に基づき、本論文では時間割引

率と日々の行動にも關係があると考えた（図 1）。日々の行動はスマートフォンやトラッカーなどのウェアラブルデバイスで正確かつ幅広く観測できる。また、Apple watch や Fitbit などのウェアラブルデバイスを装着する人々は年々増加傾向にあり [7], [22]、多くの人々の行動を観測可能な環境が整ってきている。すなわち、ウェアラブルデバイスによって観測された行動データから時間割引率を高精度に推定できれば、多くの人々に定期的に適用可能な技術となると考えられる。

本論文では、時間割引率と日々の生活の中の行動の關係を分析し、行動データから時間割引率を高精度に推定するための手法を提案する。まず、我々は 70 名の実験参加者の時間割引率をアンケートによって測定し、その後の個々人の 4 週間分の行動データを収集した。実験参加者には Fitbit トラッカーと体重計を配布するとともに、日々の食事時刻、勤務時間などを記録してもらうタスクを課し、行動イベントとして日々の睡眠、運動、食事、仕事、体重計測に関する時刻を収集した。次に、得られた行動データから大きく 3 種類の行動特徴（行動生起時刻、行動遷移、行動パターンの差異）を抽出し、時間割引率と行動特徴の關係を分析した。この結果、時間割引率と有意に相關のある行動特徴を発見した。分析で得られた興味深い相關關係の一つに、時間割引率が高い参加者ほど、今、体重が軽いことに重きを置く結果、朝食前に体重計測をしていることが分かった。分析結果に基づいて時間割引率の推定モデルを構築し、深層学習をベースとした多量の学習パラメータを要するモデルに比べて、時間割引率を高精度に推定できることを示した。

以下、本論文の構成を示す。2 章では行動データ分析や、時間割引率の相關分析の関連研究について述べる。3 章では本論文で収集したデータセットについて述べ、特に行動データの収集方法と時間割引率の測定方法について詳述する。4 章では収集した行動データを行動特徴に変換する方法を述べ、行動特徴と時間割引率の相關關係を分析する。5 章では 4 章で得られた行動特徴で、時間割引率をどの程度推定できるか実験によって精度を評価する。6 章では本論文のまとめと今後の課題について述べる。

2. 関連研究

2.1 行動データ収集に関する研究

人間の性格指標や能力と日々の行動データ間の關係性を明らかにする研究は数多く存在する。ダートマス大学を中心に取り組まれている StudentLife プロジェクト [39] では、大学生の行動を約 3 ヶ月間スマートフォンと自己申告式アンケート (EMA) によって収集し、Big Five [29] と呼ばれる心理学において人間の性格を 5 つの観点から指標化したものと、行動の相關關係を分析している。その他、同プロジェクト内では、GPA などの学業成績と試験前の各ター

ムの行動の関係分析 [40] や、社交性と行動の関係分析 [11] など、行動データから幅広く人間の性質理解に取り組んでいる。MIT で取り組まれている SNAPSHOT Study プロジェクトでも、学生にスマートフォンとウェアラブルデバイスを持たせ、行動データと共にメンタルヘルスに関わるデータを EMA によって収集している [36]。同プロジェクトでは、日々変化するストレスや気分といったメンタルヘルスに関わる人間の心理状態を予測することを目的に、ストリームとして収集される行動データを適切に処理できる深層学習モデルの研究に取り組んでいる [23]、[38] ノートルダム大学を中心に取り組まれている Tesserae プロジェクト [26] では、上記と同様にスマートフォンとウェアラブルデバイスで記録した行動データで、社会人の職業能力理解に取り組んでいる。[8] では、人間の職場での性格を複数のペルソナにクラスタリングし、どのような行動がそのペルソナに特徴的に現れるかを分析している。

このように、人間の行動データを収集しその属性や能力、日々のメンタルヘルスを推定し、どのようなミクロな行動がどれらに密接に関わっているかを研究は存在するが、時間割引率といった行動経済学的特性と日々の行動の関係を明らかにする研究はない。一方で、上記で紹介したように人間の性格や能力は、行動データを分析することで推定できていることから、本論文で取り組む時間割引率も相関関係のある行動パターンの発見、及びその推定も十分に期待できる。

2.2 時間割引率に関する研究

時間割引率を測定し、人間の属性と行動習慣を明らかにする研究は行動経済学を中心に幅広く取り組まれている。日本では、大阪大学が文部科学省の COE プログラムの一貫として実施している、「暮らしの好みと満足度に関するアンケート」[32] が広く知られている。ここでは、各年で 10,000 名程度に時間割引率を含む行動経済学的特性に関する質問と、その他の個人の基本属性や家計・消費行動等の質問をしてパネル調査をしている。このパネルデータに基づいて、[45] では時間割引率と行動習慣の相関分析をし、時間割引率と負債率、肥満率、喫煙率といった行動習慣と正の相関があるとされ、[44] では時間割引率と個人の消費行動の回帰分析によって、時間割引率が高い人は流動性資産（現金や普通預金などすぐに使える資産）を持ちたがる、限界消費性向（突発的な収入に対する消費率）が高いなどの結果を報告している。これらは大規模な人数に対し質問紙調査によってマクロな行動習慣と時間割引率との関係を分析しているものであり、本論文が取り組む日々の詳細な行動パターンと時間割引率との関係を分析している研究は知られていない。

この一方で、人間の行動や意思決定をモデリングする際に、時間割引率など行動経済学的特性を取り入れる研究も

表 1 本論文で用いるデータセットの期間と実験参加者の属性分布

収集期間	2020 年 11 月 19 日 - 2020 年 12 月 16 日 (28 日)
参加者数	70 人 (全て日本人)
年齢層	20 代:13, 30 代:21, 40 代:17, 50 代:18, 60 代:1
性別	女性:8, 男性:62

近年注目され始めている。Kleinberg ら [19] は、人間の行動とその結果得られる報酬の有向グラフの遷移において時間割引率をパラメータとして導入し、即時報酬を優先するような人間らしい意思決定をするエージェントを提案している。Redmiles ら [34] は、銀行口座を開設するようなセキュリティインシデントを内包する実験設定で、ユーザのリスクと向き合う際の意思決定過程をモデル化している。ここでは、二段階認証をとるような金銭の発生するセキュリティオプションを一律に提示するよりも、ユーザの時間割引率や危険回避率を取り入れたリスク評価モデルによってオプションを提示する方が、より人間の意思決定を再現できることを報告している。このような研究では、時間割引率は既知のものとしてモデル内のパラメータとして扱っており、本論文が取り組む日々の行動パターンから時間割引率を推定することは、人間を模倣した意思決定をするエージェントの構築や行動予測、また意思決定の介入に貢献できると考えられる。

3. データセット

時間割引率と日々観測される行動の関係を明らかにするため、本論文では 4 週間にわたる行動データの収集と時間割引率の測定実験を実施した。本データ収集実験は著者らの所属する組織の倫理委員会で審査を受け、承認されたものである。

3.1 実験参加者

我々は国内の情報通信企業でデータ収集の対象となる実験参加者を募集した。実験参加には、以下の 6 要件全てを満たしていることを前提とした。(1) 20 歳以上、(2) 体重の減量に興味がある、(3) 他の行動観測に関わる実験に参加していない、(4) 実験期間中に 1 週間以上の出張や旅行を計画していない、(5) 医師から何らかの健康指導を現在受けていない、(6) Wi-Fi 接続環境が自宅にある。募集の結果、要件を満たす 70 人を実験参加者を分析対象とした。データ収集の期間と、分析対象の実験参加者の年齢や性別に関する分布を表 1 に示す。

3.2 実験の流れ

1. 実験準備と同意確認：実験参加者には実験に関する行動を自動計測するための Fitbit トラッカー*1、体重を自動計測するための Fitbit 体重計*2、またこれらのデバイスと

*1 <https://www.fitbit.com/global/jp/home>

*2 <https://canarywww.fitbit.com/jp/aria2>

Fitbit アプリを連携するためのアカウントを配布した。実験参加者には Fitbit トラッカーは充電中以外は常に装着すること、1日1回 Fitbit 体重計で体重計測すること、毎日アンケートに回答することを依頼した。また、実験からはいつでも離脱できるという前提のもと、全ての参加者から同意を得た。これらのデバイスを問題なく扱えるか確認するため、データ収集期間前の1週間を練習期間として用意した。

2. 事前アンケート：実験開始前に、各参加者に年齢と性別、性格特性アンケート (Big-Five[29])、時間割引率を測定するためのアンケートの回答を依頼した。

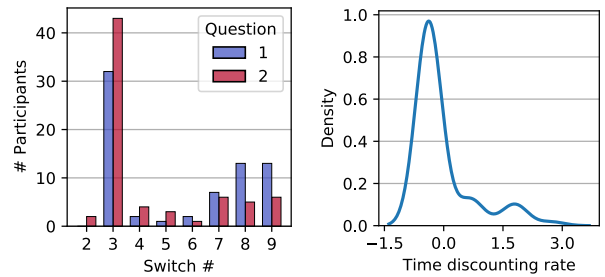
3. 行動計測：実験期間中、参加者の行動を Fitbit トラッカー及び体重計で計測した。Fitbit では心拍、活動状態、睡眠状態、体重を測定し、記録されたデータは Fitbit Web API^{*3}で毎日収集した。その他、Fitbit では収集できない食事や仕事などの日常生活に関する内容を、1日1回オンライン (Google Form) で自己報告式アンケートに回答してもらった。

4. 謝礼の条件：実験参加者に継続的な実験協力を促すために、以下のような謝礼の条件を設定し参加者に説明した。(1) 日常生活に関するアンケートに対して週5日以上の回答を提出していれば、2,000円分の謝礼を各週で受け取ることができる。(2) (1)を4週間全てで達成した場合、3,000円分の謝礼を追加で受け取ることができる。なお、Fitbit トラッカーを装着する時間が1日16時間未満となる日が週に3日以上、または体重を計測しない日が週に3日以上となった場合は、実験から強制的に辞退させる可能性があることを参加者に事前に説明した。

3.3 時間割引率の測定と結果

各実験参加者の時間割引率を測定するためのアンケートは、「暮らしの好みと満足度に関するアンケート」[32]を参考に作成した。アンケートの質問と選択項目を表2に示す。論文中のアンケート1とアンケート2では年利の昇順に表示しているが、実験参加者が回答する際は年利項目は非表示とし、順番をランダムに並び替えた。

時間割引率は、選択肢Aから選択肢Bに回答が移った設問の間の年利に該当するという考えから、その平均値を採用する。例えば、ある回答者がアンケート1に対し「#5」(年利50%)までは選択肢Aを選び、「#6」(年利100%)以降は選択肢Bを選んだとする。このとき、その回答者のアンケート1から測定される時間割引率は $\frac{50+100}{2} = 75\%$ となる。ここで、選択肢Aを選び続けた場合は「#9」(5000%)を割り当て、選択肢Bを選び続けた場合は「#1」(-10%)の損になる選択をしていることから無効回答とする。同様に、選択肢AからBに回答が移った設問が複数観測され



(a) 回答ユーザ数の分布 (b) 正規化後の時間割引率の分布
図2 アンケート回答の結果と時間割引率の分布

る場合も無効回答とする。なお、本実験においては無効回答は存在しなかった。アンケート2についても同様の方法で測定し、アンケート1と2から測定された時間割引率の平均値をその回答者の時間割引率として採用する。本論文では、Ikedaらの方法に従い[16]、時間割引率を平均0、標準偏差1になるように正規化した。

図2(a)に、アンケート1と2で回答の移った設問番号とその回答者数を示す。アンケート1と2共に「#3」(年利10%)で多くの参加者が選択肢Bに回答が移っている。すなわち、時間割引率が5%($= \frac{0+10}{2}$)の参加者が最も多い結果となっており、これは「暮らしと好みの満足度に関するアンケート」[32]の各年度の調査結果でも同様の傾向を示している。この回答結果から、時間割引率を正規化した際の密度分布を図2(b)に示す。以降の分析ではこの正規化した値を、各参加者の時間割引率として用いる。

本論文で用いる時間割引率が、どの程度先行研究の分析結果と傾向が一致しているか調査した。まず、時間割引率と相関が出やすい人間の属性の一つに「年齢」がある。年齢が高くなるほど、遅延報酬を待っている間に死亡してしまう確率が高くなることから、時間割引率も高くなると予想されている[46]。図3(a)に、今回収集したデータの年齢と時間割引率の散布図を示す。年齢と時間割引率のPearsonの積率相関係数(以降、相関係数)は有意水準 $p < .01$ で正の相関関係 $r = 0.328$ にあり、先行研究と同様の傾向を示した。また、人間の性格を5つの観点から指標化するBig Five[29]においても、神経症傾向 (Neuroticism) が高くなるほど不安を感じやすい心配性な性格傾向を示し、将来への投資を考えて少しの利益でも遅延報酬を好むことから、時間割引率が低くなると考えられている[25]。図3(b)に、参加者の神経症傾向と時間割引率の散布図を示す。神経症傾向と時間割引率は、有意水準 $p < .01$ で負の相関関係 $r = -0.325$ にあり、先行研究と同様の傾向を示した。以上の結果から、今回測定した時間割引率は参加者が無作為に回答したものではなく、一定の信頼のおけるデータ分布になっていると考えられる。

*3 <https://dev.fitbit.com/build/reference/web-api/>

表 2 時間割引率を測定したアンケート

アンケート 1				アンケート 2			
質問	選択肢 A	選択肢 B	年利	選択肢 A	選択肢 B	年利	
あなたは、ある金額をもらえることになりました。今日か 7 日後 (90 日後か 97 日後) にもらえますが、金額が異なります。もらえる日にちと金額について以下の選択肢 A または B があれば、どちらを選びますか。1 から 9 の全ての組み合わせについてどちらか好きな方を選んでください。	#	今日受取	7 日後受取	#	90 日後受取	97 日後受取	
	1	3,002 円	2,996 円	-10%	1	3,006 円	3,000 円
	2	3,000 円	3,000 円	0%	2	3,001 円	3,001 円
	3	3,008 円	3,011 円	10%	3	3,002 円	3,005 円
	4	3,005 円	3,014 円	15%	4	3,000 円	3,009 円
	5	3,008 円	3,037 円	50%	5	3,006 円	3,035 円
	6	3,009 円	3,068 円	100%	6	3,007 円	3,066 円
	7	3,001 円	3,119 円	200%	7	3,000 円	3,118 円
	8	3,003 円	3,297 円	500%	8	3,007 円	3,301 円
9	3,005 円	5,951 円	5000%	9	3,007 円	5,995 円	

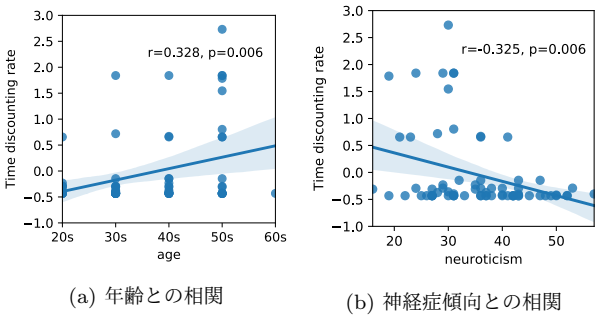


図 3 時間割引率と回答者の属性の相関

表 3 抽出した行動イベントの一覧

行動ラベル	記録方法	説明
sleep(start)	Fitbit	睡眠開始時刻
sleep(end)	Fitbit	睡眠終了時刻
active(start)	Fitbit	運動開始時刻
active(end)	Fitbit	運動終了時刻
work(start)	Diary	仕事開始時刻
work(end)	Diary	仕事終了時刻
breakfast	Diary	朝食を摂った時刻
lunch	Diary	昼食を摂った時刻
dinner	Diary	夕食を摂った時刻
diary	Diary	アンケートを記入した時刻
weight	Fitbit	体重計に乗った時刻
unequip	Fitbit	Fitbit の非装着時刻

4. 行動データと時間割引率の相関分析

4.1 分析の概要

本章では、収集したデータセットから行動パターンと時間割引率の相関関係を分析する。行動データは Fitbit トラッカー、Fitbit 体重計、自己報告式アンケートによって記録されており、本論文では特にイベント時刻として観測される行動に着目して分析した。表 3 に抽出した行動イベントの一覧を示す。記録方法の列に Fitbit と記述があるものは Fitbit トラッカーと体重計で自動計測されたもの、Diary と記述があるものは Google Form で参加者に自己申告で記録してもらったものである。Fitbit トラッカーは心拍数に応じて毎分の活動レベルを、sedentary (着座)、lightly (弱)、fairly (中)、very (強) のいずれかを割り当てる。運動に関する行動である active(start) と active(end) は、活動レベルが fairly か very と記録された期間を抽出し、その開始時刻 active(start)、その終了時刻を active(end) として割り当てた。行動ラベルの unequip は、Fitbit の非装着時刻であり、これは Fitbit トラッカーの心拍数が連続して 0 と記録されている時間が 10 分以上継続した場合に、充電などのために Fitbit を装着していない時刻として抽出した。図 4 に、あるユーザーの実験開始 4 日間の行動イベント系列の例を示す。このユーザーは日付けが変わってから sleep(start) が発生し、また weight や diary は夜に発生しやすいことがこの 4 日間に




図 4 行動イベント系列の例。breakfast, lunch, dinner は eating としてまとめて表示している。

おける傾向である。このような行動イベント時刻の傾向と時間割引率の関係を、本章では 3 つの観点から分析する。4.2 節ではある行動の生起時刻、4.3 節では 2 つの行動ペアの遷移、4.4 節では行動の生起時刻、あるいは遷移時間の差異に着目して分析する。

4.2 行動時刻に関する分析

ここでは、ユーザの行動時刻に着目した特徴と時間割引率の相関関係を見る。行動ラベル毎に、日付情報を除去した生起時刻 t の平均値を計算する。加えて、時刻情報の連続性が日付を跨ぐと損なわれてしまうことから、時刻 t を $\sin(\frac{2\pi t}{24})$ によって \sin 変換した値、 $\cos(\frac{2\pi t}{24})$ によって \cos 変換した値でも平均値を計算する。 $\sin(\frac{2\pi t}{24})$ は AM 6:00 に最大値、PM 6:00 に最小値となり、 $\cos(\frac{2\pi t}{24})$ は AM 0:00 に最大値、PM 0:00 に最小となる変換を行う。これにより、ある

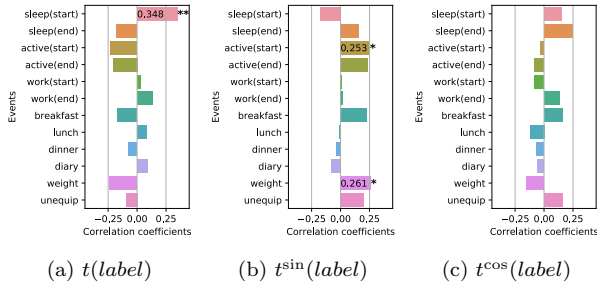


図 5 行動の平均生起時刻と時間割引率の相関.

行動をどのような時間帯でしやすいかという傾向を捉えることが可能となる．以下，ある行動ラベル $label$ の平均生起時刻を $t(label)$ ， \sin 変換後の平均生起時刻を $t^{\sin}(label)$ ， \cos 変換後の平均生起時刻を $t^{\cos}(label)$ と表記する．

図 5 にそれぞれの行動特徴について，行動ラベル別の時間割引率との相関を示す．有意水準 $p < .05$ 以下だったものは「*」を，有意水準 $p < .01$ 以下だったものは「**」をマークしている．この結果，時間割引率と有意に相関が確認された行動特徴は， $t(\text{sleep}(\text{start}))$ ($r = 0.348$, $p < .01$)， $t^{\sin}(\text{active}(\text{start}))$ ($r = 0.254$, $p < .05$)， $t^{\sin}(\text{weight})$ ($r = .261$, $p < .05$) であった．

4.3 行動間の遷移に関する分析

ここでは，ある 2 つの行動に着目したときに，その遷移パターンに着目した特徴と時間割引率の相関関係を見る．対象となる 2 つの行動ラベルに対し，どの程度の時間間隔で遷移しているかという平均遷移時間，またその遷移時間の標準偏差を計算する．平均遷移時間はある 2 つの行動がどの程度の時間間隔で起きているか，また標準偏差はその時間間隔のばらつきを評価できる．同様に，行動系列データ中で連続する 2 つの行動を抽出し，行動間の遷移確率を計算する．遷移確率は，ある 2 つの行動の連続しやすさを評価できる．以下，遷移前の行動ラベル $label1$ と遷移後の行動ラベル $label2$ について，平均遷移時間を $\mu(label1 \rightarrow label2)$ ，遷移時間の標準偏差を $\sigma(label1 \rightarrow label2)$ ，遷移確率 $p(label1 \rightarrow label2)$ と表記する．

図 6 に，行動間の平均遷移時間 (a)，遷移時間の標準偏差 (b)，遷移確率 (c) の時間割引率との相関を示す．各セルの濃淡は，行に示している行動ラベルから列に示している行動ラベルへ遷移するときの，各種行動特徴と時間割引率の相関係数の高さを示している．特に時間割引率と相関のある行動特徴は， $\mu(\text{weight} \rightarrow \text{sleep}(\text{end}))$ ($r = 0.323$, $p < .01$)， $\mu(\text{work}(\text{start}) \rightarrow \text{weight})$ ($r = 0.344$, $p < .01$)， $p(\text{weight} \rightarrow \text{breakfast})$ ($r = 0.364$, $p < .01$) であった．

4.4 行動パターンの差異に関する分析

ここでは，行動パターンの差異に着目した行動特徴と時

間割引率の相関関係を見る．行動パターンは平日と週末で大きく異なり，週末になると座りっぱなしの状態が多くなり活動量が減少することや [27]，不健康な食生活になる傾向がある [2]．このような行動パターンの差異から，週末になると体重が増加することも報告されている [33]．2.2 節で述べたように，肥満率と時間割引率は相関があり，平日と週末の行動パターンの差異に時間割引率も深く関係していると考えられる．

本論文でも，各行動の平日（月曜から金曜）と週末（土曜と日曜）の差異を捉えるために，4.2 節で用いた平均生起時刻 $t(label)$ と $t^{\sin}(label)$ ，及び 4.3 節で用いた平均遷移時間 $\mu(label1 \rightarrow label2)$ を，平日と週末で分割して計算し，その差の絶対値を用いた．以降，平日と週末の平均生起時刻の差異を $\Delta_1 t(label)$ ， \sin 変換後の平均生起時刻の差異を $\Delta_1 t^{\sin}(label)$ ，平均遷移時間の差異を $\Delta_1 \mu(label1 \rightarrow label2)$ と表記する．

一方で，平日と週末で行動パターンが異なるのは学校や仕事の有無が大きく関係しており，平日に学校や仕事で溜まった疲れやストレスを週末（休日）に解消しようとするためであるという報告がある [10]．すなわち，平日でも祝日や有給休暇など休日になる可能性があり，週末でも休日出勤など仕事をする可能性を考慮する必要があると考えられる．本論文では，各参加者の仕事の開始時刻と終了時刻を記録してもらっていることから，仕事有日と仕事無日に分割して，上記と同様の方法で差異を計算した．以降，仕事有日と仕事無日の平均生起時刻の差異を $\Delta_2 t(label)$ ， \sin 変換後の平均生起時刻の差異を $\Delta_2 t^{\sin}(label)$ ，平均遷移時間の差異を $\Delta_2 \mu(label1 \rightarrow label2)$ と表記する．

図 7 に平均生起時刻の差異の時間割引率との相関を，図 8 に遷移時間の差異の時間割引率との相関を示す．平均生起時刻の差異で時間割引率と有意に相関が確認された行動特徴は， $\Delta_2 t^{\sin}(\text{active}(\text{end}))$ ($r = 0.335$, $p < .01$) であった．また平均遷移時間の差異では，平日と週末，仕事有日と仕事無日で共通して相関が確認された行動特徴は， $\Delta_1 \mu(\text{breakfast} \rightarrow \text{sleep}(\text{end}))$ ($r = -0.312$, $p < .05$)， $\Delta_2 \mu(\text{breakfast} \rightarrow \text{sleep}(\text{end}))$ ($r = -0.309$, $p < .05$) であった．

4.5 分析結果

表 4 に，時間割引率と有意な相関を持つ行動特徴の件数を示す．+ と - の列は，正の相関と負の相関の数を示している．この結果，有意水準 $p < .05$ と $p < .01$ でそれぞれ 37 件と 5 件の行動特徴が確認された．全体から観察できることとして， $\Delta_1 \mu$ と $\Delta_2 \mu$ は時間割引率に負の相関を持ちやすいことが確認できる (4.4 節)．この結果は，平日と週末，仕事有日と仕事無日で行動パターンが異なる人は，時間割引率が低いことを示唆している．時間割引率と関係の深い行動を捉えるために， $p < .01$ の行動特徴に着目し，




図 6 行動間の平均遷移時間 (左), 遷移時間の標準偏差 (中), 遷移確率 (右) と時間割引率の相関. 各セルの色の濃淡は, 列ラベルの行動から行ラベルの行動へ遷移するときの各種特徴量と時間割引率の相関の高さを示している.

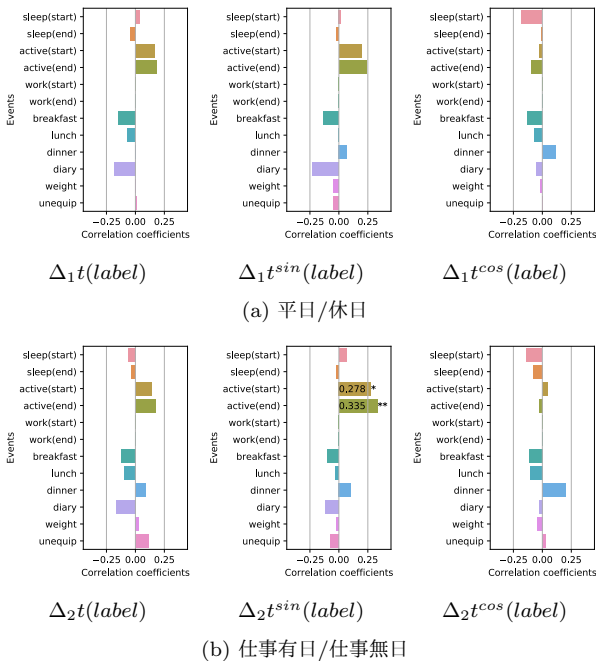


図 7 行動生起時刻の差異特徴と時間割引率の相関.

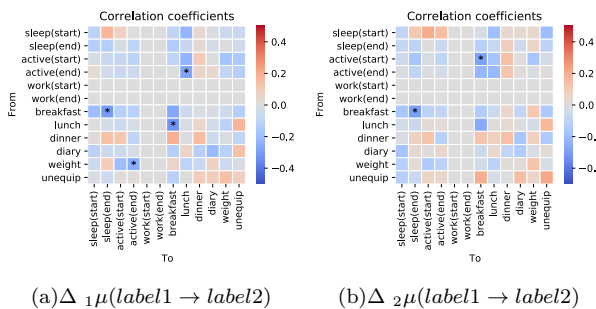


図 8 行動間の平均遷移時間の差異と時間割引率の相関. 各セルの色の濃淡は, 列ラベルの行動から行ラベルの行動へ遷移するときの各種特徴量と時間割引率の相関の高さを示している.

これまでの知見を用いて説明する.

sleep(start): 睡眠開始時刻が午前 0 時に近づくほど $t(\text{sleep}(\text{start}))$, 時間割引率は高くなる (4.2 節). ただ

し, 午前 0 時を超えると, この結果は支持されない. 厚生労働省の報告*4 によると, 年齢が高い人ほど早く睡眠をとりやすく (PM10 時から PM24 時), また年齢が若い人は日付が変わってから睡眠をとりやすい (AM0 時から 1 時). 今回のデータセットでも, 年齢が高い人ほど睡眠開始時刻 $t(\text{sleep}(\text{start}))$ が高いことが分かった. また, 高齢者ほど時間割引率が高いことも確認されている (図 3(a)). したがって, 睡眠開始時刻は時間割引率と深く関係する結果が得られた.

weight: 朝食前に体重を計測する確率 $p(\text{weight} \rightarrow \text{breakfast})$ が高いほど, 時間割引率は高くなる (4.3 節). 今回のデータ収集実験の参加者は, 体重減量に興味がある. すなわち, 参加者は将来可能な限り体重が軽いことに価値を持っている. 参加者は 1 日の中で好きなタイミングで体重を計測することが可能であり, もし参加者が将来的な体重減量をしたい遅延報酬に重きを置いているのであれば, 参加者の現在の体重を正確に把握できるタイミングで体重計測し, それに応じて食事制限や運動といった体重管理をする必要がある. 一方で, 今体重が軽いことに重きを置くような即時報酬を優先する参加者は, 1 日の中で可能な限り体重が軽いタイミングで計測すると予想される. 先行研究によると, 1 日の中で最も体重が軽いタイミングは朝食前であり [35], もし即時報酬を優先するのであれば, 朝食前に体重計測をされると考えられる. 実際, 今回のデータセットでも時間割引率が高い即時報酬を優先する参加者は, 朝食前に体重計測をする確率が高い結果が得られた. このことから, 時間割引率が高い人は, 将来的な減量が実現できなかったとしても, 「今体重が軽いこと」を優先し, 朝食前に体重計測をしていると考えられる.

active: 仕事有日と仕事無日の運動終了時刻の差異が大きいほど $\Delta_2 t^{\sin}(\text{active}(\text{end}))$, 時間割引率は高くなる

*4 <https://www.e-healthnet.mhlw.go.jp/information/heart/k-02-004.html>

表 4 抽出された行動特徴の件数

行動特徴	All	$p < .05$		$p < .01$	
		+	-	+	-
$t, t^{\sin}, t^{\cos}(\text{label})$	36	3	0	1	0
$\mu(\text{label1} \rightarrow \text{label2})$	144	7	6	2	0
$\sigma(\text{label1} \rightarrow \text{label2})$	144	2	7	0	0
$p(\text{label1} \rightarrow \text{label2})$	144	4	0	1	0
$\Delta_1 t, \Delta_1 t^{\sin}, \Delta_1 t^{\cos}(\text{label})$	36	0	0	0	0
$\Delta_2 t, \Delta_2 t^{\sin}, \Delta_2 t^{\cos}(\text{label})$	36	2	0	1	0
$\Delta_1 \mu(\text{label1} \rightarrow \text{label2})$	144	0	4	0	0
$\Delta_2 \mu(\text{label1} \rightarrow \text{label2})$	144	0	2	0	0
Total	828	18	19	5	0

(4.4). この結果は、時間割引率が低い参加者は仕事有日と仕事無日に関わらず特定の時間帯に運動し、時間割引率が高い参加者は仕事有日と仕事無日で異なる時間帯で運動していることを捉えている。先行研究の知見から、肥満傾向にある人は不規則な食生活 [30] や少ない運動量 [37] などの傾向を持つ。また時間割引率が高い人は肥満傾向にある [16]。以上のことから、時間割引率が高い人は特定の時間帯で運動していないことが考えられる。

5. 時間割引率の推定

5.1 提案手法

ここでは、4章で得られた行動特徴に基づいて、時間割引率を高精度に推定するための手法を提案する。いずれの手法においても重回帰モデルを適用し、時間割引率を推定した。

BET: 行動生起時刻 (4.2 節) に関する特徴の内、有意水準 $p < .05$ で相関が確認できた特徴集合。

BTR: 行動間の遷移 (4.3 節) に関する特徴の内、有意水準 $p < .05$ で相関が確認できた特徴集合。

BDF: 行動パターンの差異 (4.4 節) に関する特徴の内、有意水準 $p < .05$ で相関が確認できた特徴集合。

ALL.05: 全ての行動特徴の内、有意水準 $p < .05$ で相関が確認できた特徴集合。

ALL.01: 全ての行動特徴の内、有意水準 $p < .01$ で相関が確認できた特徴集合。

FILTER: **ALL.05** から、FCBF (Fast Correlation-Based Filter) [43] を用いて選択した特徴集合。FCBF は、**ALL.05** に含まれる行動特徴から時間割引率との相関係数の絶対値が高いものを順に採用し、その行動特徴と δ 以上の相関 (絶対値) を持つ行動特徴を冗長な特徴として除去する。本論文では事前実験の結果から $\delta = 0.3$ に設定した。この結果、採用された特徴数は 8 件であった。

PCA: **ALL.05** に対して主成分分析 (PCA) をし、データと主成分ベクトルの内積をとったもの。実験ではデータの説明分散比が 0.8 になるような最小主成分数

を選択した。この結果、主成分数は 11 となった。

5.2 比較手法

LSTM: 比較手法として、系列データを処理できる LSTM [13] を用いる。LSTM は深層学習を構成するモデルの一つであり、入力された系列データの長期・短期の傾向を学習できる。本論文では、系列中の行動ラベルを one-hot 表現 (行動の種類数である 12 次元) に変換し、全結合層によって特徴ベクトルにエンコードし、各タイムステップの LSTM の入力とした。LSTM は系列データを順方向に処理する層と、逆方向に処理する層の 2 層構造とした。行動系列データを順次入力していき、最終タイムステップにおける順方向の出力ベクトルと逆方向の出力ベクトルを結合し、全結合層の線形変換によって時間割引率を出力させた。誤差関数は平均二乗誤差関数を用い、ミニバッチサイズは 100 とし、評価対象以外の全てのユーザの系列データから Back Propagation Through Time (BPTT) [41] によってパラメータを学習させた。モデルの最適化には Adam [17] *5 を用いた。また、全結合層の出力ベクトル数は {64, 128, 256} から、学習の Epoch 数は {50, 100, 200} から誤差が低くなるものを選択した。

TLSTM: 比較手法として、LSTM に一部変更を加えた Time-aware LSTM (TLSTM) [4] を用いる。TLSTM は系列データ中の各タイムステップ間の遷移時間を考慮できる LSTM である。各タイムステップ間の遷移時間を入力として加え、その遷移時間を考慮するためのパラメータを LSTM 内に導入し、遷移時間に応じて短期記憶の重み、長期記憶の重みを学習することができる。実験では、上記の **LSTM** と同様の学習条件の中から、誤差が低くなるものを選択した。

5.3 評価方法

各手法の推定性能は、Leave-one-out 交差検証によって評価した。このとき、訓練データについて全ての特徴量を平均 0、標準偏差 1 になるように正規化し、そのパラメータを用いて評価データも正規化した。時間割引率の推定能力を評価するため、本論文では評価尺度として平均絶対誤差 (MAE) と平均二乗誤差 (MSE) を用いた。MAE は外れ値の影響を受けにくく、MSE は誤差が大きいほど過大に評価する。

5.4 実験結果

各手法の MAE、及び MSE を図 9 に示す。MAE と MSE ともに、FILTER が最も高い推定精度を示した。行動特徴

*5 最適化のハイパーパラメータは、 $\alpha = 0.001, \beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ とした。

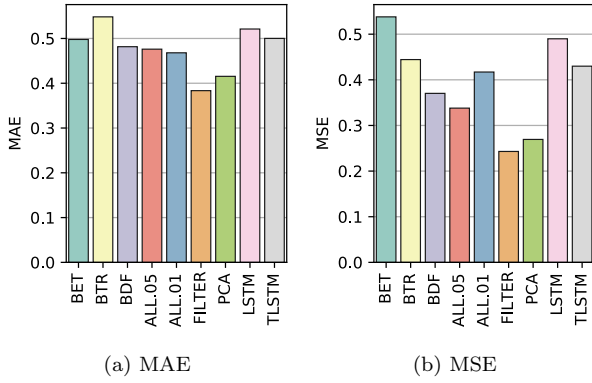


図 9 各手法の予測誤差

の種類別の精度に着目すると、MSE では行動パターンの差異を捉えた BDF が BTE と BTR に比べ高い推定性能を示した。また、BDF はこれら全てを組み合わせさせた ALL.05 とも差は小さい。このことから、行動パターンの差異を捉えた特徴が時間割引率の推定に強く寄与していることが分かる。一方で ALL.01 は ALL.05 に比べ MSE で大きく精度が低下していることから、時間割引率を捉えるための行動特徴が十分でなく、外れ値を適切に推定できていないことが考えられる。比較手法である LSTM と TLSTM では、行動間の遷移時間を考慮できる TLSTM が LSTM に比べて MAE と MSE ともに高い性能を示しており、行動を遷移時間を考慮することの有効性が示唆される。ただし、提案手法の多くが比較手法に対し精度が上回っていることから、本論文で提案した行動特徴を用いることの有効性を示している。このような深層学習を基礎としたモデルはパラメータが提案手法に比べて多く、今回のユーザ数では十分なパラメータ学習ができなかったことが考えられる。

5.5 定性分析

本節では、時間割引率推定タスクにおいて高い性能を示した FILTER に着目して、時間割引率推定において重要な行動特徴について検討する。まず、FILTER で採用された行動特徴の一覧を表 5 に、その相関係数と有意確率と共に示す。まず、4.5 節で述べた 3 種類の行動特徴である $t(\text{sleep}(\text{start}))$, $p(\text{weight} \rightarrow \text{breakfast})$, $\Delta_2 t^{\text{sin}}(\text{active}(\text{end}))$ は上位 3 件に採用されており、時間割引率の推定においても重要な行動特徴であった。採用された 8 件の行動特徴のうち 6 件が行動間の遷移を考慮したものが採用されている。すなわち、2 つの行動がどのような時間で遷移したか、あるいはその差異（平日と休日、仕事有日と仕事無日）が時間割引率の推定に重要であると考えられる。

一方で、行動間の遷移に関する特徴について、表 4 から有意水準 $p < .05$ で相関が認められたものは合計 26 件あったが、FCBF によって似た傾向を持つ行動特徴を除去すると 4 件のみとなり、約 85% の特徴が除去される結果

表 5 FILTER によって採用された行動特徴一覧

#	行動特徴	相関係数	有意確率
1	$t(\text{sleep}(\text{start}))$	0.348	0.005
2	$p(\text{weight} \rightarrow \text{breakfast})$	0.344	0.005
3	$\Delta_2 t^{\text{sin}}(\text{active}(\text{end}))$	0.335	0.006
4	$\Delta_1 \mu(\text{breakfast} \rightarrow \text{sleep}(\text{end}))$	-0.310	0.013
5	$\sigma(\text{diary} \rightarrow \text{unequip})$	0.299	0.016
6	$p(\text{work}(\text{end}) \rightarrow \text{diary})$	0.293	0.018
7	$\Delta_1 \mu(\text{active}(\text{end}) \rightarrow \text{lunch})$	-0.284	0.023
8	$\sigma(\text{sleep}(\text{start}) \rightarrow \text{lunch})$	-0.256	0.039

となった。これは、例えば $\text{sleep}(\text{start})$ や $\text{sleep}(\text{end})$ といった一定の遷移時間を持ちやすい行動ペアが存在し、 $\text{sleep}(\text{start})$ からの（への）遷移に有意に相関のある行動は、同時に $\text{sleep}(\text{end})$ からの（への）遷移にも相関を持つことを示唆している。この結果、行動間の遷移を特徴とした BTR は、多重共線性の影響で精度が低下したと考えられる。

行動パターンの差異に関する特徴は、FILTER による除去率が行動間の遷移に比べれば低く、時間割引率と高い相関を持ちやすい傾向も明らかとなった。今回は平日や休日、仕事有日や仕事無日といった差異のみに着目したが、実際の人間の生活を考えれば平日でも金曜日の夜から余暇の時間と考えて休日に近い行動をしたり、日曜日の夜は翌日の仕事への影響を考慮して平日と同様の行動をすることも十分に予想される。このように、差異のとり方をいくつか用意することによって、更に時間割引率の推定精度を向上するための行動特徴を抽出できることが考えられる。

6. おわりに

本論文では、日々記録される細かな行動データから、時間割引率を推定するタスクに取り組んだ。70 名の実験参加者から収集された行動データと時間割引率を分析し、時間割引率と高い相関を持つ行動特徴を明らかにした。特に、睡眠開始時刻、体重計測時刻、運動時刻と時間割引率の高さには有意に相関があることを示し、その要因を先行研究で得られている知見を用いながら整理した。これらの行動特徴を用いて時間割引率を推定するための回帰モデルを構築し、深層学習をベースとした比較手法に比べ高い推定性能が得られることを示した。本論文では、日々記録される細かな行動データから、

今後の課題は、大きく 2 つである。1 つ目は、今回対象とした実験参加者と異なる属性を持つ実験参加者の行動データ、及び時間割引率を測定し、本論文と同様の分析によってより頑健な行動特徴を抽出することである。今回対象とした実験参加者は男性が支配的であり、年齢層も均等になっていないことから、年齢、性別などの属性を同数として参加者のデータを収集することを検討している。

2 つ目は、自動計測可能な行動の種類を増やすことであ

る。今回は、Fitbit トラッカーと体重計によって自動計測可能な行動と、参加者に自己申告で記録してもらった行動の大きく2種類がある。例えば、学生の行動データを収集している StudentLife プロジェクト [39] では、個人にスマートフォンを配布し、会話時間、環境音、移動ログ、スマートフォンのスクリーンタイムといった様々なデータを収集しており、これらのデータが GPA や Big Five 予測に効果的であることを示している。本論文でも、このようなデバイスを用いたデータ収集を行うことで、自動計測可能な行動種類を増やし時間割引率と関係のある行動特徴を抽出できると考えている。また、今回は仕事時間はユーザに自己申告で記録してもらったが、Tesseract プロジェクト [26] のように職場と自宅に Bluetooth Beacon を置くことで、仕事の時間を自動計測する取り組みにより自己申告の負荷を軽減することも検討している。

参考文献

- [1] Almlund, M., Duckworth, A. L., Heckman, J. and Kautz, T.: *Personality Psychology and Economics*, Vol. 4, chapter 1, pp. 1–181, Elsevier (2011).
- [2] An, R.: Weekend-weekday differences in diet among U.S. adults, 2003–2012, *Annals of Epidemiology*, Vol. 26, No. 1, pp. 57–65 (2016).
- [3] Ariely, D. and Wertenbroch, K.: Procrastination, Deadlines, and Performance: Self-Control by Precommitment, *Psychological Science*, Vol. 13, No. 3, pp. 219–224 (2002).
- [4] Baytas, I. M., Xiao, C., Zhang, X., Wang, F., Jain, A. K. and Zhou, J.: Patient Subtyping via Time-Aware LSTM Networks, *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 65–74 (2017).
- [5] Callen, M.: Catastrophes and time preference: Evidence from the Indian Ocean Earthquake, *Journal of Economic Behavior and Organization*, Vol. 118, pp. 199–214 (2015).
- [6] Cameron, L. and Shah, M.: Risk-taking behavior in the wake of natural disasters, *Journal of Human Resources*, Vol. 50, No. 2, pp. 484–515 (2015).
- [7] Clover, J.: More Than 100 Million People Worldwide Use an Apple Watch, <https://www.macrumors.com/2021/08/26/apple-watch-active-user-base-100-million/> (2021).
- [8] Das Swain, V., Saha, K., Rajvanshy and et al.: A Multisensor Person-Centered Approach to Understand the Role of Daily Activities in Job Performance with Organizational Personas, *Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 3, No. 4, pp. 1–27 (2019).
- [9] Doyle, J.: Survey of Time Preference, Delay Discounting Models, *Judgment and Decision Making*, Vol. 8, No. 2, pp. 116–135 (2013).
- [10] Fritz, C., Sonnentag, S., Spector, P. E. and McInroe, J. A.: The weekend matters: Relationships between stress recovery and affective experiences, *Journal of Organizational Behavior*, Vol. 31, No. 8, pp. 1137–1162 (2010).
- [11] Harari, G. M., Müller, S. R., Stachl, C., Wang, R., Wang, W., Bühner, M., Rentfrow, P. J., Campbell, A. T. and Gosling, S. D.: Sensing sociability: Individual differences in young adults’ conversation, calling, texting, and app use behaviors in daily life, *Journal of Personality and Social Psychology*, Vol. 119, No. 1, pp. 204–228 (2020).
- [12] Hardisty, D., Fox-Glassman, K., Krantz, D. and Weber, E.: How to measure time preferences: An experimental comparison of three methods, *Judgment and Decision Making*, Vol. 8, pp. 1–15 (2013).
- [13] Hochreiter, S. and Schmidhuber, J.: Long Short-term Memory, *Neural computation*, Vol. 9, pp. 1735–1780 (1997).
- [14] Ikeda, S., Kang, M.-I. and Ohtake, F.: Hyperbolic discounting, the sign effect, and the body mass index, *Journal of Health Economics*, Vol. 29, No. 2, pp. 268–284 (2010).
- [15] Jackson, S. E. and Schuler, R. S.: Understanding Human Resource Management in the Context of Organizations and their Environments, *Annual Review of Psychology*, Vol. 46, No. 1, pp. 237–264 (1995).
- [16] Kang, M.-I. and Ikeda, S.: Time discounting and smoking behavior: Evidence from a panel survey, *Health Economics*, Vol. 23, No. 12, pp. 1443–1464 (2014).
- [17] Kingma, D. P. and Ba, J.: Adam: A Method for Stochastic Optimization, *ICLR* (2015).
- [18] Kirby, K. N. and Maraković, N. N.: Delay-discounting probabilistic rewards: Rates decrease as amounts increase, *Psychonomic Bulletin & Review*, Vol. 3, pp. 100–104 (1996).
- [19] Kleinberg, J., Oren, S. and Raghavan, M.: Planning Problems for Sophisticated Agents with Present Bias, *Proceedings of the 2016 ACM Conference on Economics and Computation*, pp. 343–360 (2016).
- [20] Krahn, M. and Grafni, A.: Discounting in the Economic Evaluation of Health Care Interventions, *Medical Care*, Vol. 31, No. 5, pp. 403–418 (1993).
- [21] Kureishi, W., Paule-Paludkiewicz, H., Tsujiyama, H. and Wakabayashi, M.: Time preferences over the life cycle and household saving puzzles, *Journal of Monetary Economics*, Vol. 124, pp. 123–139 (2021).
- [22] Laricchia, F.: Number of active users of Fitbit from 2012 to 2020, <https://www.statista.com/statistics/472600/fitbit-active-users/> (2022).
- [23] Li, B. and Sano, A.: Extraction and Interpretation of Deep Autoencoder-Based Temporal Features from Wearables for Forecasting Personalized Mood, Health, and Stress, *Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol. 4, No. 2, pp. 1–26 (2020).
- [24] Liedekerke, L. v.: Time, Discounting and Value, *The Economic Journal*, Vol. 105, No. 430, pp. 749–751 (1995).
- [25] Manning, J., Hedden, T., Wickens, N., Whitfield-Gabrieli, S., Prelec, D. and Gabrieli, J. D.: Personality influences temporal discounting preferences: Behavioral and brain evidence, *NeuroImage*, Vol. 98, pp. 42–49 (2014).
- [26] Mattingly, S. M., Gregg, J. M., Audia, P. and et al.: The Tesseract Project: Large-Scale, Longitudinal, $i\ddot{u}$ In Situ, $i\ddot{u}$ Multimodal Sensing of Information Workers, *Proceedings of the Extended Abstracts of the 2019 CHI Conference on Human Factors in Computing Systems*, pp. 1–8 (2019).
- [27] McCarthy, S.: Weekly patterns, diet quality and energy balance, *Physiology & Behavior*, Vol. 134, pp. 55–59 (2014).
- [28] Mischel, W., Ayduk, O., Berman, M., Casey, B., Gotlib,

- I., Jonides, J., Kross, E., Teslovich, T., Wilson, N., Zayas, V. and Shoda, Y.: 'Willpower' over the life span: Decomposing self-regulation, *Social cognitive and affective neuroscience*, Vol. 6, No. 2, pp. 252–256 (2011).
- [29] Mount, M. and Barrick, M.: The Big Five personality dimensions: Implications for research and practice in human resources management, *Research in personnel and human resources management*, Vol. 13, No. 3, pp. 153–200 (1995).
- [30] Nicklas, T. A., Baranowski, T., Cullen, K. W. and Berenson, G.: Eating Patterns, Dietary Quality and Obesity, *Journal of the American College of Nutrition*, Vol. 20, No. 6, pp. 599–608 (2001).
- [31] Odum, A. L.: Delay Discounting: I'm a k, You're a k, *J. of the experimental analysis of behavior*, Vol. 96, No. 3, pp. 427–39 (2011).
- [32] of Social, I. and Research, E.: Open Survey Data Japan Household Panel Survey on Consumer Preferences and Satisfaction (JHPS-CPS), https://www.iser.osaka-u.ac.jp/survey_data/survey_eng.html.
- [33] Racette, S. B., Weiss, E. P., Schechtman, K. B., Steger-May, K., Villareal, D. T., Obert, K. A. and Holloszy, J. O.: Influence of Weekend Lifestyle Patterns on Body Weight, *Obesity*, Vol. 16, No. 8, pp. 1826–1830 (2008).
- [34] Redmiles, E. M., Mazurek, M. L. and Dickerson, J. P.: Dancing Pigs or Externalities? Measuring the Rationality of Security Decisions, *Proceedings of the 2018 ACM Conference on Economics and Computation*, pp. 215–232 (2018).
- [35] Reyes, N. R., Oliver, T. L., Klotz, A. A., LaGrotte, C. A., Vander Veur, S. S., Virus, A., Bailer, B. A. and Foster, G. D.: Similarities and Differences between Weight Loss Maintainers and Regainers: A Qualitative Analysis, *Journal of the Academy of Nutrition and Dietetics*, Vol. 112, No. 4, pp. 499–505 (2012).
- [36] Sano, A., Phillips, A., Yu, A., Mchill, A., Taylor, S., Jaques, N., Czeisler, C., Klerman, E. and Picard, R.: Recognizing academic performance, sleep quality, stress level, and mental health using personality traits, wearable sensors and mobile phones, *Proceedings of the Wearable Implant Body Sensor Networks*, pp. 1–6 (2015).
- [37] Shaw, K., Gennat, H., O'Rourke, P., and Del Mar, C.: Exercise for overweight or obesity, *Cochrane Database of Systematic Reviews*, Vol. 4 (2006).
- [38] Suhara, Y., Xu, Y. and Pentland, A. S.: DeepMood: Forecasting Depressed Mood Based on Self-Reported Histories via Recurrent Neural Networks, *Proceedings of the 26th International Conference on World Wide Web*, pp. 715–724 (2017).
- [39] Wang, R., Chen, F., Chen, Z., Li, T., Hararia, G., Zhou, S. T. X., Ben-Zeev, D. and Campbell, A. T.: StudentLife: Assessing Mental Health, Academic Performance and Behavioral Trends of College Students using Smartphones, *Proceedings of the ACM Conference on Ubiquitous Computing*, pp. 3–14 (2014).
- [40] Wang, R., Harari, G., Hao, P., Zhou, X. and Campbell, A.: SmartGPA: How Smartphones Can Assess and Predict Academic Performance of College Students, *Proceedings of the 2015 ACM International Joint Conference on Ubiquitous Computing*, pp. 295–306 (2015).
- [41] Werbos, P.: Backpropagation through time: what it does and how to do it, *Proceedings of the IEEE*, Vol. 78, No. 10, pp. 1550–1560 (1990).
- [42] Yamane, S., Takahashi, T., Kamesaka, A., Tsutsui, Y. and Ohtake, F.: Socio-Emotional Status, Education, and Time-Discounting in Japanese Non-Smoking Population: A Multi-Generational Study, *Psychology*, Vol. 4, No. 2, pp. 124–132 (2013).
- [43] Yu, L. and Liu, H.: Feature Selection for High-Dimensional Data: A Fast Correlation-Based Filter Solution, *Proceedings of the 20th International Conference on Machine Learning*, pp. 856–863 (2003).
- [44] 盛本晶子: 双曲割引と消費行動, *行動経済学*, Vol. 2, pp. 49–59 (2009).
- [45] 池田新介: 自滅する選択, chapter 2, 東洋経済新報社 (2012).
- [46] 晝間文彦, 池田新介: 経済実験とアンケート調査に基づく時間割引率の研究, *金融経済研究*, No. 25, pp. 14–33 (2007).