

ウェブ調査に基づく深層学習を用いた ネット依存モデルの構築と検証

正 司 哲 朗*・吉 村 治 正*

Construction and Validation of Internet Addiction Model
Using Deep Learning Based on Web Surveys

Tetsuo SHOJI and Harumasa YOSHIMURA

要 旨

2020年4月から多くの大学で、コロナウイルス感染拡大を防止するために、対面授業から遠隔授業への変更を余儀なくされた。大学生は遠隔授業を受講するために、ネットを利用する機会が増え、ネットに依存するリスクが高まっている。ネット依存は、健康被害などを引き起こす可能性があるが、ネット依存に関する明確な尺度が存在しないため、判定することが難しい。そこで、本研究の目的は、大学生を対象にネット依存に関するウェブ調査を実施し、ネット依存モデルを構築することでネット依存を推定することである。具体的には、まず、得られた回答データからネット依存の自覚に対する有意差が認められる質問項目を抽出した。次に、抽出された質問項目の回答データをもとに、深層学習を用いてネット依存モデルを構築した。さらに、ネット依存の自覚が曖昧な回答者に対して、構築したネット依存モデルを適用したところ、依存傾向が推定したものと一致したため、ネット依存モデルの有用性が確認できた。

キーワード：ウェブ調査、インターネット依存、スマートフォン依存、深層学習

I はじめに

2020年4月から多くの大学で、コロナウイルス感染拡大を防止するために、対面授業から遠隔授業への変更を余儀なくされ、2021年度もコロナウイルス感染が収束しないため、一部の授業を除き、引き続き遠隔授業が継続される事態となった。遠隔授業の方法は、一般的には、「オンデマンド型」と「リアルタイム型」の2つに大別される。オンデマンド型は、受講者がポータルサイト、LMS（Learning Management System）、動画配信サイトなどに掲載されている資料や映像などの教材を好きな時間にアクセスして学習を行うものであるが、その反面、自ら計画を立て

て学習する必要があるため時間管理が難しい。一方、リアルタイム型は、対面授業のように、あらかじめ開始される時間が決められており、その時間に教員から配信される映像を Zoom や Google Meets などの会議ツールアプリケーションを利用して、双方向で視聴するものである。しかし、通信障害などの理由で受講できない場合があり、何度も見返すことが難しいため、リアルタイムで配信される映像を録画し、オンデマンド型のように何度も見られるようにする場合もあるが、録画に関しては、受講者の音声や受講者が映り込むため、受講者への配慮も必要である。このように「オンデマンド型」「リアルタイム型」の双方には、メリット、デメリットが存在する。

さらに、授業に対する受講者の捉え方にも様々あり、対面授業よりも遠隔授業を好む受講者がいたり、遠隔授業でもオンデマンド型を希望する受講者がいたりする。これは、受講者の視聴環境、居住地域の感染状況、授業内容、履修状況等、受講者一人一人の状況が異なり、一概にどちらかに統一することはできない。また、授業内容によっては、リアルタイム型に適しているものもあり、逆にオンデマンド型に適しているものもある。

このような問題を改善する方法の1つとしてハイフレックス型がある。ハイフレックス型は、大学で行われている授業を中継して自宅でも視聴できるようにするものであり、講義室の収容人数を減らすことができ、感染防止にもつながる。しかし、授業準備などが対面授業で実施するよりも時間がかかり、板書などを撮影する場合には、複数カメラの利用、高解像度カメラの導入、カメラワークなどの工夫が必要になってくる。また、板書代わりに、タブレット端末などを用いて手書き文字を配信する場合もあるが、映像配信の他にも様々な機器を操作しながら授業を行うため、これらの IT 機器の操作に慣れている必要がある。最近では、このようなハイフレックス型（対面授業＋リアルタイム映像配信）＋オンデマンド型を提供する大学も出てきており、受講者に合わせた授業形態を選ぶことも可能になってきている。しかし、対面授業とオンデマンド型では教授方法が異なるため、授業準備に相当な時間を要し、様々なサポートが必要となってくる。このように、大学では、コロナ禍の影響により、遠隔授業を始めとする様々な取り組みが加速度的に行われているが、大学生たちは、普段のインターネット利用に加えて、授業でも必然的にインターネットを利用する機会が増えてきている。

近年、スマートフォンの使いすぎによる体調不良、健康被害、集中力低下などを引き起こす可能性が高い「スマートフォン依存」が社会問題として取り上げられている。「スマートフォン依存」という言葉が使われ始める前には、1990年代にインターネットが普及した際にも、インターネットを病的に長時間利用している状態を「インターネット依存」と呼ばれていた。「インターネット依存」の概念は、1998年にピッツバーグ大学のキンバリー・ヤングによって提唱された（Young,1998）。現在では、携帯電話依存（Takao et al.,2009）やスマートフォン依存（Park & Lee,2011）という言葉が使われているが、スマートフォン依存を含めたインターネット依存に関する定義は、まだ統一されておらず明確な尺度が存在しないため、これらの依存を客観的に判定することが難しい。

そこで、本研究の目的は、コロナ禍において大学生が、遠隔授業も含めて日常的にインターネットを利用している実態を調査し、得られた調査データをもとに、スマートフォンやPCを含めたインターネット依存（以降、ネット依存と呼ぶ）モデルを構築し、依存判定を行うことである。

具体的には、本研究におけるネット依存モデルは、次のようにして構築する。まず、ネット依存の自覚症状を尋ねた質問において、「そう思う」「そう思わない」と回答した回答データをもとに、有意差が認められる質問項目を抽出する。次に、これらの回答データを学習データとして、深層学習を用いて2クラス分類（ネット依存の有無）ができる分類器を設計する。本研究では、この分類器をネット依存モデルと呼ぶことにする。最後に、構築したネット依存モデルを用いて、ネット依存に関しての自覚が「どちらかというと思う」「あまりそうは思わない」と回答した回答者に対して、構築したネット依存モデルを用いてネット依存かどうかを推定する。ネット依存に無自覚な場合には、改善しようとする意思が働かず、知らずにネット依存が進んでしまう可能性があるため、早期に自覚する必要があるため、ネット依存モデルを構築することで、明確な尺度がないネット依存の判定が可能となり、自覚を促すことができる。

II 関連研究

1. スマートフォン依存に関する調査

スマートフォン依存に関する研究は盛んに行われている。例えば、大学生を対象にスマートフォンに対する依存傾向と、日常生活に対する主観的な評価（極めて良好～極めて良好ではない）、私的自己意識・公的自己意識に関する調査を実施し、スマートフォン依存傾向の強さを従属変数として分析・考察した研究がある。この研究において、スマートフォン依存傾向の調査項目は、「1. どんどこでもスマートフォンの電源を切りたくない。2. 家の中でもスマートフォンを肌身離さず持ち歩く。3. 特別な目的がなくてもスマートフォンを操作する。4. 深夜でもスマートフォンを操作する。5. 人と話しながら、スマートフォンを操作する。6. 何時間も続けてスマートフォンを操作する。」の6項目あり、5件法で回答する形式である。公的自己意識と日常生活に対する主観的な評価の相互作用が、スマートフォン依存傾向の強度に影響を与える可能性が示されている（三島、2019）。また、スマートフォン依存に関する明確な定義が存在しないなか、依存尺度の開発を目指した研究もある。質問紙の設計は、Internet Addiction Diagnostic Questionnaire (IADQ) (Young,1998) を参考に、ブレインストーミング法を適用して42項目の質問項目を抽出している。各質問項目の回答形式は、「該当する」、「やや該当する」、「あまり該当しない」、「全く該当しない」の4件法を利用している。これらの回答結果をもとに因子分析を行い、最終的には、「ネットコミュニケーションへの没頭」、「スマホの優先と長時間使用」、「ながらスマホとマナーの軽視」の3つをスマートフォン依存の尺度としている（戸田・西尾ほか、2015）。さらに、スマートフォンの依存尺度設計において、使用時間が指標に用いられることが多いが、スマートフォンの使用場面を用いて指標を設計する試みがなされている。使用場면을指標とすることで、スマートフォンの使用状況が生活行動や健康状態に及ぼす影響を検討するには有用であり、スマートフォンの多使用者は、朝食欠食行動と身体的愁訴が増大するリスクがあることを示唆している（井上・小林ほか、2019）。

一方、筆者らも大学生を対象としたスマートフォンの利用実態に関するウェブ調査を実施している。得られた回答データをもとに因子分析を行い、「利用の優先」、「利用に対する罪悪感」、「SNS

投稿・閲覧」の3つの因子が抽出できることがわかった。それをもとに階層的クラスタ分析を行い、クラスタ1（「利用の優先」、「利用に対する罪悪感」、「SNS投稿・閲覧」の因子得点が比較的高いグループ）、クラスタ3（「利用の優先」、「利用に対する罪悪感」、「SNS投稿・閲覧」の因子得点が比較的低いグループ）、クラスタ2（クラスタ1とクラスタ3の中間的なグループ）に分かれることがわかった。クラスタ1は、一人暮らしの割合が多く、クラスタ3は、家族同居の割合が多い。クラスタ1と3間には有意差が認められたが、これらのクラスタとスマートフォンの依存特徴までは明らかにできなかった（正司・吉村、2020）。

上記に述べたように、スマートフォン依存の関係性を調べる方法は様々あるが、質問項目が研究目的によって異なるため、明確な尺度設計を行うことができない。そこで、本研究では、ネット依存の自覚があるかどうかを尋ねる質問を追加した調査紙を設計する。従来研究では、設計した質問項目からネット依存傾向を探るボトムアップ型であるのに対して、本研究では、ネット依存の自覚を自ら回答者に尋ね、それに関連する質問項目を抽出するトップダウン型の方法である。さらに、本研究では、ネット依存の自覚に対して、有意差が認められる質問項目の回答を学習データとして、深層学習に基づきネット依存かネット依存ではないかを推定する分類器を構築する。この分類器がネット依存モデルとなり、従来のネット依存尺度を求める方法とは異なる。

2. 深層学習の利用

現在、深層学習（Deep Learning）は、画像認識、音声認識、テキストマイニングなど、様々な分野で幅広く活用されている。深層学習は、機械学習手法の1つであり、入力されたデータからクラス分類や回帰を行う手法である。これまでの機械学習では、データに対して、人手で特徴量を設計していたため汎用性が低く、異なるデータが入力される度に、特徴量を人手で設計しなおす必要があった。一方、深層学習は、人手では特徴量の設計は行わず、大量のデータを利用することで、自動的に特徴量を組み合わせた設計が可能になり汎用性も高く、様々な分野において数多くの研究がなされている。例えば、パッケージデザインの好意度予測に深層学習を用いた研究が行われている。具体的には、実際の商品パッケージデザインの各画像に対して、評価者1000人を対象に1から5までの5段階でスコアを付与し、評価者の年齢、性別をもとに8セグメントでスコアの平均を求めている。さらに、パッケージデザインのメタデータは、カテゴリとブランドスコアの2種類を用いている。セグメントごとに、画像データとメタデータを学習させ、全セグメントの好意度スコアの平均を出力し、高い精度で予測が可能となっている（夏・坂元ほか、2020）。また、動物考古学分野において、筆者は、鳥の骨部位を同定するために深層学習を用いており、比較的高い同定精度が得られている（正司・木山ほか、2021）。本研究では、社会学分野において、ウェブ調査から得られた回答データをもとに深層学習を用いて、ネット依存モデルを構築するものである。他分野のように膨大な学習データはないが、どの程度の精度が得られるか、また有効性を検証するものである。

III ウェブ調査紙の設計と実装

1. ウェブ調査紙の設計

ウェブ調査紙の回答形式は、紙の調査紙と同様に、一般的には、「多肢択一型」、「多肢選択複数回答型」、「数値入力型」、「自由記述型」、「その他」に分類することができる。ウェブ調査紙の設計方法に関しては、筆者らがこれまで行ってきた設計方法（正司・吉村、2020）に基づくが、調査項目によって異なる場合がある。本研究では、上記で述べた回答形式の分類のうち、タイプA：多肢択一型、タイプB：多肢選択複数回答型、タイプC：数値入力型、タイプD：自由記述型、タイプE：その他（多肢選択複数回答型＋自由記述）の5つに設定し、各質問項目のデータ構造は、番号（質問順番）、質問文、タイプ（A～E）、回答の選択肢とする。なお、タイプCとタイプDは、1つにまとめることが可能であるが、数値入力の場合には、全角数字、半角数字、漢数字が混じる可能性が高く、データ分析時には半角数字に統一する必要がある。よって、数値入力とテキスト入力を区別するために、便宜上、タイプを分け、数値入力の場合は、半角数字しか入力できないように制限をかけている。さらに、質問項目の管理では、回答形式に依存しないビューモデルを定義し、上記の回答形式の分類に基づいて表示形式が自動的に変更できるようにしているため、質問項目の変更・挿入・削除、質問項目順の変更が容易に実現できる。しかし、回答者の回答に応じて、質問項目をスキップする場合には、調査紙の設計に依存するため、その都度、カスタマイズが必要である。

2. ウェブ調査紙の実装

本研究では、本学で開講されている社会調査実習で設計された「大学生を対象としたネット依存に関する調査」の調査紙を、先ほど述べた設計に基づきウェブ調査紙に実装した。質問項目数は73あり、そのうち、ネットに関連する質問は43項目である。それ以外の質問項目は、リモート授業関連（7項目）、生活習慣、健康、学業、生活環境、性格などである。ネットに関連する質問には、「持っているインターネット接続機器」（1項目）、「インターネットの利用目的・時間」（2項目）、「ゲームの利用状況」（7項目）、「SNSの利用状況」（4項目）、「動画・音楽の視聴状況」（6項目）である。また、「インターネットの利用に関して感じていること」（23項目）に関しては、ヤングのインターネット依存に関する調査項目（Young,1998）を参考にしてている。

本研究におけるウェブ調査紙は、HTML（Hyper Text Markup Language）で表示し、上記の回答形式の分類において、回答形式は、タイプAの多肢択一型、タイプBの多肢選択複数回答型、タイプEのその他（多肢選択複数回答型＋自由記述）の3つで構成されている。タイプAはradioフォーム、タイプBはcheckboxフォーム、タイプEはcheckboxフォーム＋textフォームで実装した。また、デフォルトのHTMLフォームでは、ボタンが小さく、スマートフォンでは選択しづらくなるため、CSS（Cascading Style Sheets）を用いてカスタマイズした。スマートフォンの画面サイズの最適化に関しては、JavaScriptを利用すれば、スマートフォンの画面サイズのチェックを行い、画面サイズに応じた最適な表示を行うことが可能であるが、JavaScriptはウェ



図1 ウェブ調査紙の表示画面

ブラウザで解釈するため、ブラウザの種類によっては動作が不安定になる恐れがある。

このため、上記のように HTML と CSS のみで実装し、ブラウザ依存を可能な限り軽減させた。また、データベースとの連携、条件分岐などの処理は、サーバサイドで実行する PHP (Hypertext Preprocessor) を用いて実装した。さらに、ユーザ ID、パスワード、回答内容が漏洩しないように、セキュリティを強化する必要があるため、SSL 通信による暗号化のほか、セッションハイジャックや SQL インジェクションに対する対策も行っている。

図1に実装したウェブ調査紙の画面を示す。図1(a)はタイプA: 多肢択一型の回答形式、図1(b)はタイプB: 多肢選択複数回答型、図1(c)はタイプE: 多肢選択複数回答型+その他記述の回答形式であり、Apple社 iPhone Xs Max (画面サイズ 6.5 インチ) で表示した画面である。選択した回答は、赤字で表示できるようにしているため、回答者の選択ミスが、極力少なくなるように設計している。

IV ウェブ調査の実施とネット依存モデルの構築

1. 実験環境

ウェブ調査、および深層学習を用いたネット依存モデルの構築には、以下に示す実験環境で行った。

【ウェブ調査のためのサーバ環境】

- CPU : Intel (R) Xeon (R) W2135 @ 3.70-4.50GHz、メモリ : 64GB

- OS：Ubuntu 16.04.7 LTS
- ウェブサーバ用ソフトウェア：nginx 1.16.0、php 7.3.16、mysql 5.7.26

【ネット依存モデルの構築環境】

- CPU：Intel (R) Corei9 2.9GHz、メモリ：32GB
- OS：macOS Mojave 10.14.6
- 深層学習用ソフトウェア：TensorFlow-CPU 2.4.0、Keras 2.4.0

本研究で実装したウェブ調査紙は、回答端末の OS を問わず、現在、一般的に利用されている多数のウェブブラウザで利用可能である。また、スマートフォンの画面サイズが異なる場合でも、画面レイアウトを崩すことなく利用できるものである。さらに、深層学習を用いたネット依存モデルを構築するため、深層学習のフロントエンドとして Keras、バックエンドとして CPU 版の Google TensorFlow を利用した。深層学習では、通常、GPU を用いて並列計算を行うことで高速演算が可能になるが、本研究で扱うデータは少なく、テキストデータであるため、CPU 処理でも十分である。

2. 回答者の利用端末とブラウザの種類

ウェブ調査は、2021年6月30日～7月31日までの期間で実施した。調査対象者は、奈良大学の学部生 757 名（うち、文学部 90 名、社会学部 667 名）であり、有効回答数は 283 名で回答率は 37.4% であった。回答者（重複アクセスを含む）が利用した OS をみると、iOS が 38.5%、AndroidOS が 12.2%、iPadOS が 0.3%、Windows 系 OS が 46.7%、macOS が 2.4% であった。また、回答者が利用したウェブブラウザについて調べてみると、Safari が 40.8%、Microsoft Edge が 27.3%、Google Chrome が 31.0% であったが、多くの回答者が Safari を利用している。これは iOS、iPadOS、macOS の利用者の多くは、標準のブラウザ Safari を使っているからである。また、本学では、Google サービスを利用した遠隔授業が多いため、Windows 系では、Microsoft Edge よりも、Google サービスと相性がよい Google Chrome を利用していることが多いと推察される。

回答者の学年は、図 2 (a) に示す通りであり、2 年生がもっとも多い。また、インターネットに接続する機器の所持については、スマートフォンが 97.9%、ノート PC が 79.2%、タブレット端末が 25.8%、デスクトップ PC が 19.8% であり、すべての回答者が何らかのインターネット接続機器を所持しており、図 2 (b) に各機器に対する利用人数を示す。さらに、2020 年度は、ほとんどの授業が遠隔授業になり、2021 年度入学生はノート PC を必携化したため、全学年において、ノート PC の所有率が高い傾向になっている（表 1）。

3. ネット依存の自覚と有意差が認められる質問項目

ネット依存の自覚があるかどうかを調査したところ、「そう思う」が 18.0%、「どちらかというところ思う」が 37.5%、「あまりそうは思わない」が 27.9%、「そう思わない」が 13.4%、「よくわからない」が 3.2% であり、「そう思う」と「どちらかというところ思う」を合わせると半数以上が、ネット依存の自覚があるという結果になった。

ネット依存の自覚に関する質問と各質問の回答間に有意差が認められるかを、 χ^2 検定（有意

水準 5%) で行ったところ、表 2 に示す通りになった。なお、ネット依存の回答の種類に応じて、以下のように A から C の 3 つに分類している。A は、「そう思う」「どちらかというと思う」「あまりそうは思わない」「そう思わない」「よくわからない」の 5 種類の回答を、B は A の回答から「よくわからない」を除いた 4 種類の回答を、C は「そう思う」「そう思わない」の 2 種類の回答をもとに検定したものである。表 2 から回答の種類によって、各質問項目に有意差が認められるかどうか異なっていることがわかる。このことから、回答者がネット依存かそうでないかの判断には個人差が生じている場合があり、「どちらかというと思う」「あまりそうは思わない」「よくわからない」の回答には、曖昧な部分が含まれていることが推察される。ネット依存と自覚しているかどうかは主観的なものであり、質問項目のうち、該当するものが何個以上、あるいは選択した回答によって点数化し、個数もしくは点数の総計でネット依存と捉える方法もあるが、そこに絶対的な指標があるわけでもない。

このため、本研究では、ネット依存モデルを構築するにあたり、ネット依存であるか、ネット依存でないかの 2 種類の回答（表 2 の C 列）で有意差が認められた質問項目 28 個（Q2、Q5、Q13、Q31、Q34～Q36、Q40、Q41、Q43～Q47、Q49～Q56、Q59、Q61、Q63、Q68～Q70）を利用して、深層学習に基づくネット依存モデルを構築することにする。モデル構築に利用する質

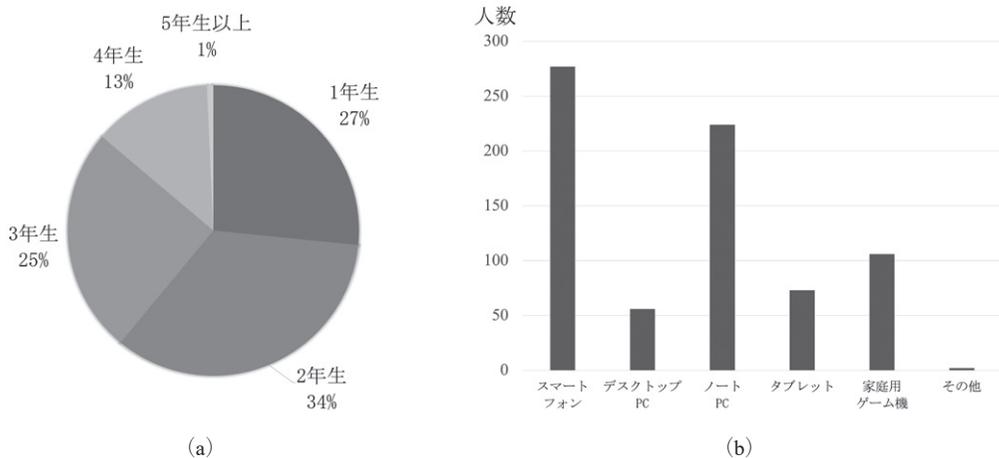


図 2 回答者の学年とアクセス端末

表 1 学年別所有端末の割合

回生	スマートフォン	デスクトップ PC	ノート PC
1 年生	98.7%	21.3%	80.0%
2 年生	95.9%	19.6%	76.3%
3 年生	100.0%	18.3%	83.1%
4 年生	97.3%	18.9%	78.4%
5 年生以上	100.0%	50.0%	100.0%

表2 ネット依存の自覚と各質問項目間の χ^2 検定結果

質 問 項 目	A	B	C
Q2. 平日に、学校の授業も SNS もゲームもすべて含めて、一日のうちインターネットを使っている時間はどれくらいですか。	0.000*	0.011*	0.015*
Q4. ゲームをする人にうかがいます。どのようなジャンルのゲームをしますか。	0.044*	0.018*	0.332
Q5. では、そのうち一番よくやるのは、どのジャンルのゲームですか。	0.005*	0.001*	0.039*
Q13. SNS で知り合った人、SNS でしか会ったことのない友人はいますか。	0.296	0.178	0.039*
Q19. インターネットを使って他の作業をしている時に動画・音楽配信サービスを同時に使うことがありますか。	0.005*	0.002*	0.103
Q25. リモートの授業を受けていて「リモートなら手を抜いてもバレない」と思うことはありますか。	0.006*	0.013*	0.114
Q28. あなたは今、何年生ですか。	0.065	0.020*	0.283
Q29. あなたの成績は、他の人よりもよい方だと思いますか、それとも悪い方だと思いますか。	0.019*	0.046*	0.285
Q31. ゲームも SNS も授業も含め、インターネットをする時間は、コロナ禍になる前と比べて増えましたか、それとも変わりませんか。	0.001*	0.032*	0.019*
Q34. この一年ほどで視力が落ちた、目が疲れやすくなったと感じますか。	0.000*	0.000*	0.047*
Q35. この一年ほどで不眠になったり目覚めが悪くなったと感じますか。	0.000*	0.000*	0.002*
Q36. 不眠や目覚めが悪くなった人にうかがいます。お昼ごろに眠たくなったり、集中力が途切れることがありますか。	0.000*	0.002*	0.002*
Q37. この一年ほどで体調を崩す、具合が悪くなるなど、健康に問題がでたことがありますか。	0.038*	0.237	0.366
Q40. 気がつくと思っていたよりも長い時間ネットをしている。	0.000*	0.000*	0.001*
Q41. ネットを長く利用して家で役割をおろそかにした。	0.000*	0.000*	0.000*
Q43. ネットで新しく知り合いを作ることがある。	0.049*	0.026*	0.011*
Q44. ネットを利用する時間が長すぎると周囲の人に文句を言われたことがある。	0.025*	0.011*	0.007*
Q45. ネットをしている時間が長すぎて勉強をする時間がなくなる。	0.000*	0.000*	0.000*
Q46. ネットが原因で勉強に集中できない。	0.000*	0.000*	0.000*
Q47. 他にやらなければならないことがあっても、まずメールや SNS をチェックする。	0.000*	0.000*	0.000*
Q49. 日常生活から気をそらそうとしてネットで時間を過ごすことがある。	0.000*	0.000*	0.000*
Q50. 気がつけば、またネットを楽しみにしていることがある。	0.000*	0.000*	0.000*
Q51. ネットのない生活は退屈でむなしく、わびしいと思うことがある。	0.000*	0.000*	0.000*
Q52. ネットをしている最中に他の人に邪魔されて、いらいらしたり怒ったりすることがある。	0.001*	0.002*	0.022*
Q53. 夜遅くまでネットをしていて寝る時間がなくなることがある。	0.000*	0.000*	0.000*
Q54. ネットをしていないときでも、ネットのことを考えてぼんやりしていることがある。	0.000*	0.000*	0.000*
Q55. ネットをしていて「あと少しでやめよう」と自分に言い訳していることがある。	0.000*	0.000*	0.000*
Q56. ネットをする時間を減らそうと思っているが、なかなかできない。	0.000*	0.000*	0.000*
Q57. ネットをしている時間を人に聞かれると、とっさにウソをついてしまう。	0.016*	0.007*	0.092
Q59. ネットをしていない時にイライラして、ネットを始めると気分がよくなることがある。	0.001*	0.000*	0.012*
Q61. ネットや SNS をやっている自分の方が、普段の自分よりも自分らしいと思う。	0.138	0.087	0.045*
Q63. 人から受け入れられていないのではないかと不安になることがある。	0.001*	0.000*	0.019*
Q68. 一人で行動するのが苦手だ。	0.088	0.053	0.029*
Q69. 初対面の人と話すのは楽しい。	0.186	0.121	0.024*
Q70. 人と対面である会話は、はっきりいって苦手だ。	0.015*	0.008*	0.001*

* $\alpha < 0.05$

問項目は、ヤングのインターネット依存に関する質問項目以外にも、不眠と集中力の低下や一人で行動するのが苦手、初対面の人と話すのは楽しい、人と対面で話すことが苦手などの質問項目が含まれている。

4. ネット依存モデルの構築と検証

本研究では、先の χ^2 検定の結果からネット依存に関して、表2のC列で有意差が認められた質問項目の回答結果を学習データ（説明変数）、ネット依存の自覚に対して、「そう思う」「そう思わない」と回答した結果を正解ラベル（目的変数）として、2クラス（依存の有無）を分類する多層パーセプトロンのニューラルネットワークモデルを以下のようにして構築する。なお、本研究では、このニューラルネットワークモデルを学習データで学習させることで構築された分類器がネット依存モデルとなる。まず、本研究で扱っている学習データ、および正解ラベルは、質的データであり数値計算することができないため、それぞれを One-hot ベクトルに変換している。例えば、学習データの Q2 の質問「一日のうちインターネットを使っている時間はどれぐらいですか」の場合、回答の種類は、1. 30分以内、2. 2時間以内、3. 2~4時間ぐらい、4. 4~6時間ぐらい、5. 6~8時間ぐらい、6. 8~12時間ぐらい、7. 12時間以上の7種類あり、無回答を含めると8種類ある。例えば、回答が7種類の場合、One-hot ベクトル化すると、[0,0,0,0,0,0,1] になり、1つの成分が1で残りの成分がすべて0のようなベクトルになる。One-hot ベクトル化することにより、入力する学習データの次元数は、有意差が認められた質問項目28、回答の種類が最大11となるので、 28×11 になる。学習に利用したデータは89件であるが、そのうち、ネット依存モデルの検証用に10%（ランダムに選定した9件）を引いた80件を学習データとして利用する。

本研究では、全結合層を7層利用し、1層目の入力層には、学習データ 28×11 次元を入力し、1層目から6層目までの活性化関数は Rectified Liner Unit (ReLU) を、7層目の出力層の活性化関数は softmax を利用している。ReLU 関数は、入力が0以下であれば0を出力し、0以上であれば、そのままの値を出力するものであるのに対し、softmax 関数は、出力が0から1であり、出力の総和が1になることから出力を確率とみなすことができ、分類問題に用いられている。また、過学習を防ぐために出力結果を間引くドロップアウト層を入れ、ニューラルネットワークのユニットをランダムに50%カットしている。

図3に、本研究で構築したニューラルネットワークモデルを示す。なお、括弧内の数字は unit 数であり、モデルの更新パラメータは50,598個である。ニューラルネットワークモデルのパラメータ更新に利用する目的関数には、交差エントロピーを用いた。交差エントロピーとは、2つの確率分布（正解の分布と予測の分布）がどれくらい離れているかの指標で、分類問題の予測の正しさの指標として用いられるものであり、予測が正解に似ているほど、2つの確率分布の交差エントロピーは小さくなる。この目的関数の値を最小にするようにニューラルネットワークのパラメータを更新するが、そのときに利用する最適化アルゴリズムには RAdam (Rectified Adaptive Moment Estimation) を用いた。RAdam は、移動平均と学習率調整の2つを組み合わせ、適応学習率の分散を自動的に抑えられるように、Adam (Adaptive Moment Estimation) に組み込んだ

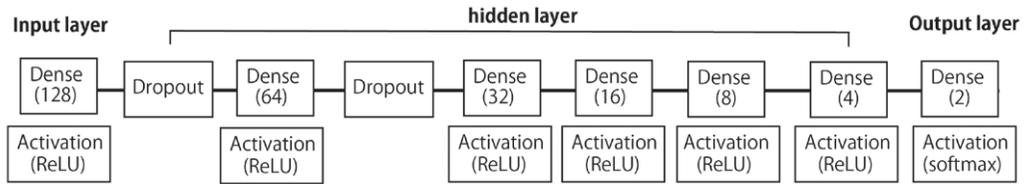
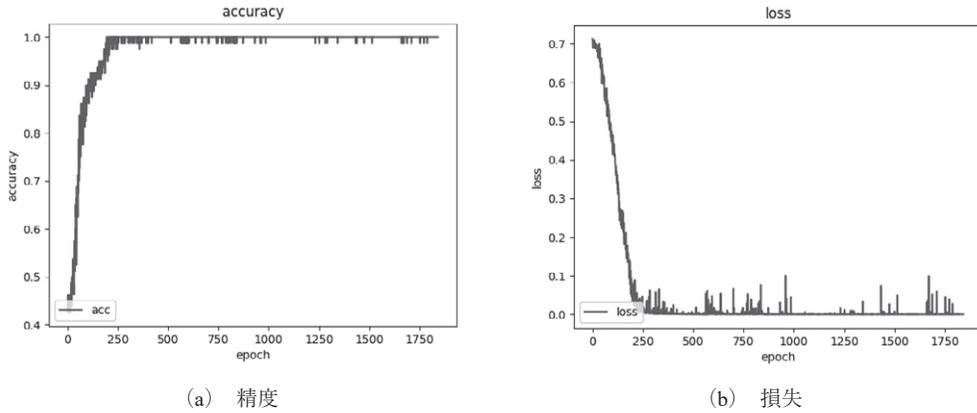


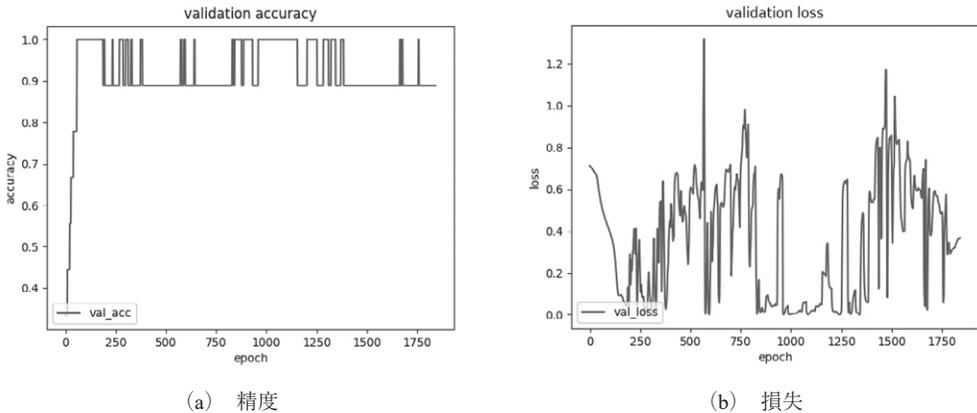
図3 構築したニューラルネットワークモデル



(a) 精度

(b) 損失

図4 学習回数 (epoch) による学習データの精度と損失



(a) 精度

(b) 損失

図5 学習回数 (epoch) による検証データの精度と損失

ものである。

ニューラルネットワークのパラメータを更新する回数 (epoch) については、検証用データの交差エントロピーの損失 (loss) がある程度、減少しなくなった時点で学習を終了させ、ネット依存モデルを構築した。図4は学習回数による学習データの精度と損失を示している。学習データに対する精度は、学習回数が195回を超えると精度の極端な変化がほぼ無くなっている(図4(a))。学習データに対する損失も学習回数が、195回を超えるあたりからは、多少、損失値が不安定ながらもエントロピーが最小になっている。(図4(b))。図5は、学習回数による検証デー

タの精度と損失を示している。検証データに対する精度は、学習回数が60回以降精度が0.9から1.0の間を繰り返している(図5(a))。また、損失については、学習回数によって損失が変化しており、検証データの精度と損失は連動している。(図5(b))。本研究では、検証データの損失が最小になり、精度が最大になるように学習を繰り返し、パラメータを更新したところ、学習回数(epoch)は1758回になった。その結果、学習データに対しての損失が**0.002**、精度が**100.00%**、検証用データに対しての損失が**0.058**、精度が**100.00%**となり、構築したネット依存モデルの精度が比較的高いことを示している。

上記で構築したネット依存モデルを用いて、ネット依存の自覚に対して、「どちらかというと思う」「あまりそうは思わない」「よくわからない」と回答した回答データをもとに、「ネット依存あり」か「ネット依存なし」を推定すると表3ようになった。この推定結果に対して χ^2 検定を行うとp値が0.00となり、有意水準5%で有意差が認められたので残差分析を行った。

残差分析の結果、調整済み残差の絶対値が5%の標準正規偏差値1.96以上であれば5%水準で有意であると認められるので、調整済み残差の絶対値が1.96以上のものは、「どちらかといえばそう思う」「あまりそうは思わない」と回答したものであった。「どちらかといえばそう思う」と回答した回答者には「ネット依存あり」と判定される傾向が高く、「あまりそうは思わない」と回答した回答者には、「ネット依存なし」と判定される傾向が高いという結果になった。また、「よくわからない」と回答した回答者には、正方向にも負方向にも1.96以下なので、有意な差が認められなかった。

本研究で構築したネット依存モデルは、有意差が認められた「コロナ禍になる前と比べてインターネットをする時間が増えたかどうか」の質問項目を加えているため、コロナ禍の影響を含めたものになる。実際に、「Q31. ゲームもSNSも授業も含め、インターネットをする時間は、コロナ禍になる前と比べて増えましたか、それとも変わりませんか。」という質問に対して、「だいぶ増えた・少し増えた」と回答したものは74%もあった。さらに、「Q22. この学期に入ってから、一日あたり何時間ぐらいリモートの授業を受けていますか(授業をうけている時間だけでなく、課題の作成や授業の準備などの時間も含まれます。)」では、リモート授業を受けたり、レポート課題に取り組んだりすることによって、ネット利用時間が増えていることがわかる(図6)。

本研究では大学生を対象にしたネット依存に関する調査であるため、学修するためにインター

表3 ネット依存モデルに基づくネット依存の推定

選択回答	ネット依存なし	ネット依存あり	合計
どちらかといえばそう思う(人数)	28	78	106
構成比(%)	26.42	73.58	100.00
調整済み残差	-4.60	4.60	
あまりそうは思わない(人数)	46	33	79
構成比(%)	58.23	41.77	100.00
調整済み残差	3.98	-3.98	
よくわからない(人数)	6	3	9
構成比(%)	66.67	33.33	100.00
調整済み残差	1.59	-1.59	

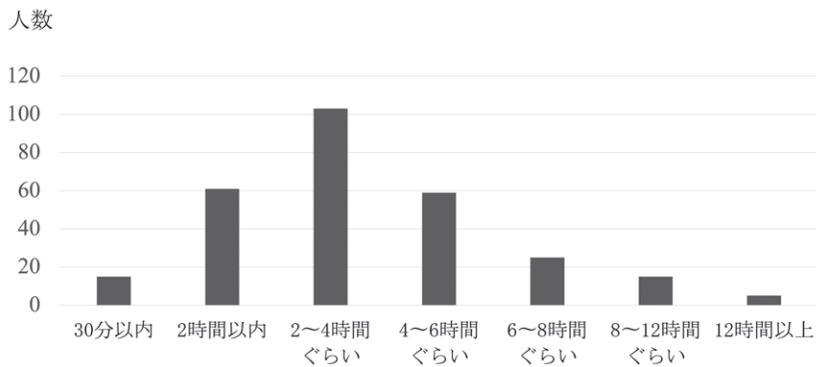


図6 一日あたりリモート授業の受講時間

ネットを利用することで、結果的にインターネットの利用時間が増えたとしても、それはネット依存とは呼ぶことができず、ネット依存の捉え方には個人差もある。このため、本研究では、明確に自覚している回答者（ネット依存かそうでないか）の回答データをもとに、ネット依存モデルを構築し、曖昧に「どちらかといえばそう思う」「あまりそう思わない」と回答した回答者に対して、構築したネット依存モデルで推定したところ、回答者のネット依存傾向と一致していることが確認できた。

V おわりに

本研究では、コロナ禍において、大学で開講されている授業のほとんどが遠隔授業になり、受講者は、対面授業の代わりにインターネットを利用した映像配信やオンデマンド教材を活用しながら授業を受けている。これにより、大学生のインターネット利用は、コロナ禍以前に比べて利用時間が明らかに増えている。近年、スマートフォンの過度な利用によるスマートフォン依存が社会問題になっているが、遠隔授業を受けるにあたり、スマートフォンやノートPCなどを利用してインターネットの使用も増えてきている。このため、本研究では、大学生を対象としたネット依存に関するウェブ調査を実施した。質問項目は、ネット関連を始め、リモート授業関連、生活習慣、健康、学業、生活環境、性格である。ネット依存に関する概念は、ヤングによって提唱された以降、他のスマートフォン依存やインターネット依存の調査においても、ヤングの質問項目が用いられていることが多いが、医学的には依存に関する明確な定義はない。

そこで、本研究では、ネット依存の自覚に関する回答データをもとに、有意な差が認められる質問項目を抽出したところ、ネット関連質問以外では、視力が落ちた・目が疲れやすくなった、不眠と集中力の低下、一人で行動するのが苦手、初対面の人と話すのは楽しい、人と対面で話すことが苦手という質問項目が含まれていた。しかしながら、リモート授業に関する質問項目が含まれていなかったため、ネット依存を調べるにあたり、本研究の調査では、遠隔授業の影響がどれくらいあったかどうかは不明である。ネット依存モデルの構築では、まず、ネット依存の自覚

に関して、「そう思う」「そう思わない」と回答した回答者のデータをもとに、有意差が認められた質問項目を抽出した。次に、これらの回答データを学習データ、ネット依存の自覚の有無（「そう思う」「そう思わない」）を正解データとして、深層学習を用いたニューラルネットワークを設計し、学習データで学習することで、ネット依存モデルを構築した。構築したネット依存モデルの精度は、未学習データに対して、比較的高い精度を示した。本研究で構築したネット依存モデルは、ネット依存を判定する分類器となる。最後に、構築したネット依存モデルを用いて、ネット依存の自覚に関して、曖昧に「どちらかといえばそう思う」「あまりそう思わない」と回答した回答者に対して、構築したネット依存モデルで推定したところ、回答内容と推定したネット依存の傾向が一致したため、ネット依存モデルの有用性が確認できた。

ネット依存が進行することによって、体や心の問題、家族的・社会的問題に発展する可能性もあるため、無自覚の場合には、自ら改善しようとする機会を失うことにもなりかねないため、早期に、ネット依存を自覚するように促す必要がある。本研究で構築したネット依存モデルを用いることで、ネット依存かどうかを自動判定できるため、ネット依存の自覚を促すには有効である。ただし、本研究の調査対象は大学生であったため、調査対象を広げた場合、同じような傾向があるのかを調査する必要があり、構築したネット依存モデルが適用できるかどうかとも検証する必要がある。

謝辞

本研究の一部は、JSPS 科研費 18H00940 の助成を受けたものである。また、奈良大学社会学部総合社会学科の社会調査実習受講者においては、調査項目の設計や実装したウェブ調査紙の動作確認などに協力頂いた。

参考文献

- 井上久美子・小林三智子・長澤伸江（2019）：女子大学生における使用場面数を指標としたスマートフォンの使用状況と健康状態や生活行動に対する自己管理能力との関連．日本健康教育学会誌、27（2）、164-172.
- 正司哲朗・吉村治正（2020）：ウェブ調査の設計と大学生を対象としたスマートフォン利用実態に関する調査．奈良大学紀要、48、99-111.
- 正司哲朗・木山克彦・内田幸子・江田真毅（2021）：深層学習を用いた鳥類の骨部位認識に関する検討．日本文化財科学会第38回大会研究発表要旨集、20-21.
- 戸田雅裕・西尾信宏・竹下達也（2015）：新しいスマートフォン依存尺度の開発．日本衛生学会誌、70、259-263.
- 夏博恵・坂元英樹・汪雪テイ・山崎俊彦（2020）：深層学習を用いたパッケージデザインの好意度予測．第34回人工知能学会全国大会論文集．
- 三島浩路（2019）：スマートフォン依存傾向に関連する要因．現代教育学部紀要、11、21-28.Park, B.W.& Lee,K.C.（2011）：The effect of users characteristics and experiential factors on the compulsive use of the smartphone. Ubiquitous Computing and Multimedia Application, 151,438-446.
- Takao, M., Takahashi,S.& Kitamura, M.（2009）：Addictive personality and problematic mobile phone use.

CyberPsychology&Behavior,12 (5) ,501-507.

Young,K.S. (1998) :Internet addiction: The emergence of a new clinical disorder. CyberPsychology&Behavior,1 (3) , 237-244.

Abstract

Since the beginning of the coronavirus pandemic in the winter of 2019, most of the face-to-face classes offered at universities have been changing to remote classes. For this reason, university students will have more opportunities to use the internet than ever before, increasing the risk of becoming addicted to it. Internet addiction has a high potential to cause health hazards, loss of concentration, etc. However, it is difficult to determine internet addiction because there is still no unified definition or clear scale for it. Therefore, the purpose of this study was to conduct a web survey of university students about internet addiction and construct an internet addiction model from the obtained response data. Specifically, we first extracted from the question items that showed significant differences in the awareness of internet addiction. Next, we used the response data of the extracted questions as training data to construct an internet addiction model using deep learning. Finally, when the internet addiction model was applied to respondents whose perception of internet addiction was ambiguous, the addiction tendency was consistent even among respondents whose perception of internet addiction was ambiguous. Therefore, we were able to confirm usefulness of the internet addiction model.

Keywords: web surveys, internet addiction, smartphone addiction, deep learning