

深層学習による車いす利用者向け経路探索 のための路面評価に関する研究

隅田康明^{1,a)} 林政喜¹ 合志和晃¹ 松永勝也²

概要: 車いすでの移動においては、路面上の僅かな段差や凹凸も障害となるが、こうした路面状態の計測は人力に頼っているのが現状であり、手動車いす利用者に対する移動支援のためには路面情報の定量的かつ効率的な計測が必要である。従来は目視による計測の他、摩擦係数や路面のひび割れ状態をセンサによって計測する手法が主であったが、近年では画像認識の精度向上が著しく、路面の摩擦係数やひび割れ状態を推定するといった研究もおこなわれている。車いす利用者向けの経路探索システムを構築するにあたり、路面状態の客観的評価を画像認識によって行えるようになれば、簡便な計測を行えるようになり、路面情報の計測に係るコスト削減を計ることが出来るようになると思われる。本研究では、深層学習によって電動車いす移動時に必要とする消費電力を路面画像から推定するモデルを構築し、その推定精度の検証を行った。

キーワード: 深層学習, 画像認識, 路面評価, 車いす利用者, 経路探索

A Study on Road Surface Evaluation for Route Finding for Wheelchair Users Using Deep Learning

YASUAKI SUMIDA^{1,a)} MASAKI HAYASHI¹
KAZUAKI GOSHI¹ KATSUYA MATSUNAGA²

Abstract: In order to provide mobility support to manual wheelchair users, quantitative and efficient measurement of road surface information is necessary. Recently, the accuracy of image recognition has improved significantly, and research is being conducted to estimate the friction coefficient and cracks in the road surface. When constructing a route finding system for wheelchair users, if objective evaluation of road surface conditions can be performed using image recognition, it will be possible to perform simple measurements and reduce the cost of measuring road surface information. In this study, we developed a model that uses deep learning to estimate the power consumption required when moving an electric wheelchair from road images, and verified the accuracy of the estimation.

Keywords: Deep learning, Image recognition, Road Surface Evaluation, Wheel chair users

1. はじめに

1.1 背景

近年、我が国では少子高齢化が深刻な問題となっており、

高齢者を標準とした都市環境の整備が求められている。QOL の向上のためには独力で円滑な移動を行えることも重要であり、高齢者や歩行が困難な肢体障害者の移動の質を改善することは現代社会における課題である。こうした問題を背景に、高齢者や障害者の移動の質に関する研究が多く行われている。例えば、移動の質について杉山らは移動容易性、空間快適性、情報提供性、介助性の4つの評価軸による総合評価を行っており、利用者の違いによって差

1 九州産業大学
Kyushu Sangyo University
2 九州大学
Kyushu University
a) sumida@ip.kyusan-u.ac.jp

異がある場合の改善案を示している[1]。また、土井らは高齢化社会において、安全・安心して移動できる交通環境整備への要望が強くなるとしている[2]。今後の高齢化社会に適した環境整備において高齢者や障害者にとっても移動しやすい歩道の整備は必須であり、バリアフリー新法（高齢者、障害者等の移動等の円滑化の促進に関する法律）をはじめとし、高齢者や障害者でも独力で移動できる都市環境の整備が進められている。しかしながら、歩道を含む都市環境のバリアフリー化はいまだ十分ではなく、歩道のバリアフリー化がなされているかについての定量的な評価を行い、それを基にした経路の提示を行えるシステムの開発が必須といえる。

1.2 関連研究

手動車いす使用者向けの経路探索、案内システムについてはつぎに述べるような先行研究が行われている。Matthews らが提案している経路探索システム MAGUS (Modelling Access with GIS in Urban Systems) [3]は、市販の GIS (ArcView GIS) の機能を拡張し、車いす移動の障害となる段差や勾配等の情報を入力することで経路探索を行っている。また、岡本ら[4]も市販の GIS ソフトに商店街の利用可能店舗を入力することで、車いす使用者を含むハンディキャップ者への経路情報を提供する研究を行っている。U-Access は Sobek ら[5]が提案する Web ベースシステムであり、MAGUS などの GIS アプリケーションベースのシステムよりも高い汎用性を目指して開発されている。Kasemsuppakorn らは段差の数や路面の材質などに重みを付け、より楽に移動できる経路を探索する方法を示している[6][7]。また、山本ら[8]は複数のユーザによる投稿情報を共有することで、人海戦術での広範囲の情報収集を行い、それを基にした経路探索を行うシステムについての研究を行っている。多数のユーザによる情報収集を目的としたシステムとしては、井上らによる iPhone を用いたバリア情報記録・公開システムや[9]、Menkens ら[10]の EasyWheel システムなどがある。また、国土交通省は 2014 年 3 月に歩道上のバリアを迂回する経路を探索する「バリアフリー経路探索」の試験的な公開を開始している[11]。

車いす使用者が移動するための最適な経路を探索するためには、何をコストとした経路探索を行うかが重要となってくる。Matthews ら、Sobek ら、Kasemsuppakorn らは、経路上の障害（距離、段差の数、勾配、通路幅、路面の材質など）にそれぞれ重みを設定してコストとし、そのコストが最小となる経路を提示している。山本らの研究や、「バリアフリー経路探索」では目的地まで最短距離で移動できる経路の探索を基本に、車いすで移動出来ない障害物を迂回する方法での経路提示を行っている。牧ら[12]、岡村ら[13]は手動車いすに取り付けた加速度計によって、Ishida ら[14]は路面の縦断プロファイルによって、金野ら[15]は台車に設

置した測域センサによって路面凹凸の測定・評価を試みている。こうした先行研究からも、車いす使用者が移動する経路の探索においては、路面上の段差や材質といった路面を移動する際にかかる負荷が重要と考えられる。また、路面の摩擦係数については歩道上の摩擦係数を測定する機器が市販されており、路面の勾配については、水平器や車いすにスマートフォンや角度センサを設置して測定するものなどがある[16][17]。

こうした先行研究や測定機器は路面の勾配や段差、凹凸、摩擦といったものを個々に測定し評価するものであり、歩道の評価を行うためには、これらを組み合わせた測定・評価を行う必要がある。こうしたことから、我々も以前の研究で電動車いすの消費電力によって手動車いす移動時の仕事量を推定する方法を提案してきた[18,19]。これによって、電動車いす走行時に必要とする消費電力から、手動車いすを含む車輪付き移動体の移動時に必要とする仕事量の推定が可能となり、この推定値を用いた経路探索によって、車いす使用者がより楽に移動可能な経路を提示することが可能なことを示した。しかしながら、路面の種々のバリア情報を計測するためには多くのセンサが必要であり、広範囲の計測が求められる経路探索システム用の計測機器として、より簡便に路面の情報を計測できるものも必要と考えられる。

1.3 研究目的

こうしたことから、本研究では路面上の障害物を専用の計測機器などを用いずに計測する手法として、路面画像の認識による推定を試みた。近年では画像認識の精度向上が著しく、路面の摩擦係数やひび割れ状態を推定するといった研究もおこなわれている。一般的に安価で入手可能な単眼カメラの画像から路面を移動した際の負荷を推定出来れば、路面のバリア情報の計測コストを大きく下げることができ、車いす向けのバリアフリーマップや経路探索・案内サービスの展開や維持にも大きく貢献できるものと考えられる。

2. 路面移動時の負荷推定

2.1 路面移動時の負荷

本研究では、路面画像から車いすによって移動した際の負荷を推定する。車いす移動時の負荷は、路面の摩擦係数、凹凸やひび割れの大きさ、微細な段差の高さや形状、車いすの前輪・後輪の慣性力、前輪・後輪車軸の粘性軸受抵抗、前輪・後輪の転がり抵抗などといったパラメータを用いた計算によって推定することも可能であるが、実用的には多くのパラメータを正確に計測することは困難である。そのため、電動車いす移動時に必要とする消費電力を路面画像から推定することにした。電動車いす移動時に必要とする

消費電力は路面走行時の負荷の大きさによって大きくなるため、移動時に電力を多く消費する路面は移動時より大きな力を必要するものと考えることが出来る。電動車いす移動時に消費する電力からは、手動車いすをはじめとする車輪付き移動体で移動する際に必要とする仕事量を推定できるため[19]、電動車いす移動時の消費電力の推定を許容できる精度で行うことが出来れば、車いす移動時に必要となる仕事量の推定も間接的に行えるようになる。図 1 は、図 2 の電動車いすによって平坦なアスファルト、コンクリート、レンガ路面 (図 3) を走行した際の消費電流 (1m 走行時の平均値) と消費電流から推定した手動車いす移動時に要する仕事量の推定値、手動車いすで実測した仕事量を示したものである。路面の材質によって必要となる消費電流がそれぞれ異なり、それをもとにして手動車いす移動時に要する仕事量を推定出来ていることがわかる。本研究では、電動車いす移動時の消費電力 (消費電流) を計測しながら走行し、走行時の前方の路面画像を単眼カメラで撮影、撮影した路面画像から消費電力を推定することとした。

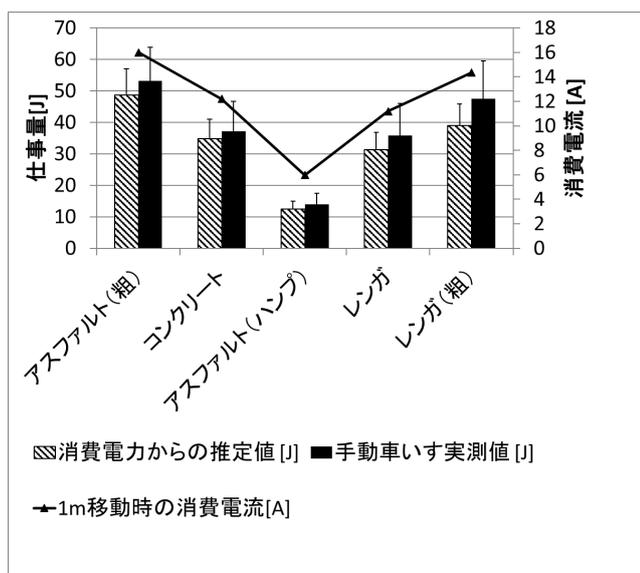


図 1 走行負荷 (消費電流と仕事量の推定値) 測定結果
 Figure 1 Measurement results of consumed current per metre.

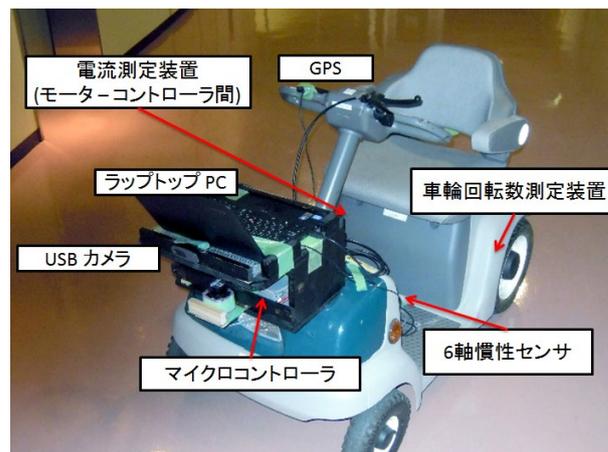


図 2 計測用電動車いす実装写真

Figure 2 Photograph of moving difficulty measurement device.



図 3 測定路面

Figure 3 Measured various road surface.

2.2 消費電流の計測と路面画像の撮影

移動時の電力計測に使用する電動車いすは、自操用ハンドル形電動車いす (モンパル ML-100 : HONDA) のモーターとコントローラ間に小抵抗 (0.077Ω) を取り付け、抵抗の両端の電圧を OP アンプによって 2.5 倍に増幅したうえでマイクロコントローラ (AVR ATMEGA 644P - 20PU:AVR 社) によって、200ms の標準化間隔で計測した。また、電圧値は 5 回分の移動平均を行うことでノイズの影響を軽減した。消費電力については、単位距離を移動した際のものとするため、後輪裏側に白黒交互パターンを貼り付け、フォトインタラプタによって白色の回数を計測する車輪回転数測定装置を取り付けて、電動車いすの移動距離を計測した。電圧値およびフォトインタラプタからの車輪回転数は、マイクロコントローラによって計測し、ラップトップ PC によって記録した。また、今回の計測では電動車いすに搭乗する人の重量は服なども含めて毎回 70kg になる様に重りで調整し、搭乗者の体重の変動によって計測する消費電力に差が生じないようにした。

前方路面の画像は一般流通しており安価に入試可能な USB カメラ (HD WEBCAM C270 : Logicool 社) によって撮影した。撮影画像は 640×480 ピクセルのサイズの 24bit カラーで撮影したが、推定のために必要なのは路面の画像の

みであるため画像内の 100×100 ピクセルを切り取って使用した。

路面の撮影画像は実際に電動車いすがその場所を通過する前に撮影されたものであるため、電動車いすの移動速度とカメラの設置角度から、電動車いすが撮影路面を通過した時点の計測値を用いるようにした。

2.3 路面画像からの消費電流推定方法

路面の画像を深層学習によって認識する研究としては、路面のひび割れの位置と大きさから損傷度合を推定するもの[20]、伸縮装置やマンホール、補修跡などを検出するもの[21]、自動車での走行時の路面入力騒音を予測するもの[22]などがある。従来の機械学習では認識が困難であったものも深層学習によって推定できることが示されており、電動車いすの消費電流についても深層学習によって推定できるものと考えた。

3. 深層学習による消費電流推定

3.1 深層学習による消費電流推定モデル作成

路面画像から消費電流を推定するために、深層学習用の python ライブラリである tensorflow (1.14.0), keras (2.2.4) を用いて、ImageNet[23]学習済みモデルである Xception V1 モデル[24]の 109 層以降を転移学習させ、消費電力を出力とする回帰モデルを作成した。学習のための教師データは、電動車いす走行時の消費電流の実測値をラベルとした路面撮影画像として、1855 枚のラベル付き画像を用意した。学習画像は多いほど推定精度も高くなることが期待できるため、それぞれの画像の左右を反転させた画像を加えた。計 3710 枚の教師データのうち、3610 枚を学習用、100 枚を検証用の画像とした。路面画像は九州産業大学内で撮影し、屋外だけでなく屋内の画像も撮影して学習データとした。評価のための損失関数は二乗平均平方根誤差(RMSE)を用いて画像データから消費電流を回帰推定するモデルを学習させた。

図 4 は学習時の損失(Loss)と学習回数(Epoch)を示したグラフである。損失関数の評価値は 36.71(教師データのラベルは 225~857 の範囲)であった。

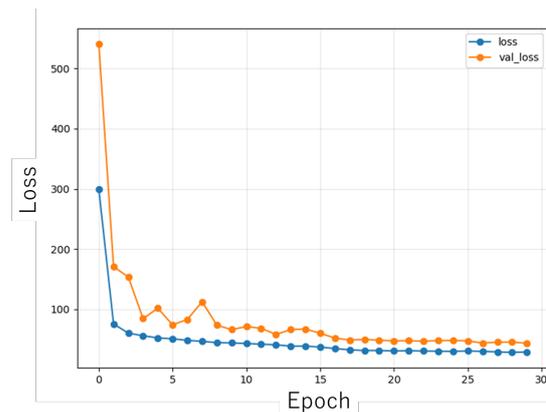


図 4 学習曲線 (損失と学習回数)

Figure 4 Learning curve (Loss-Epoch).

3.2 作成した消費電流推定モデルによる推定結果

作成した消費電流推定モデルによる、推定値と実測値を図 5 に示す。縦軸は消費電流の推定値と実測値を示し、横軸は検証用画像の番号を示している。検証用画像は実測値(教師データのラベル)が小さい順に並べている。実測値の小さい画像の推定で大きな誤差が生じている物があるが、消費電流値が 500A を超えるあたりからは良い推定結果を得られている。推定値の相対誤差(実測値-推定値の絶対値を実測値で除したもの)は、平均で 6.5%、最大で 84.1%であった。平均 6.5%の相対誤差は画像認識による推定の精度としては十分に高いものであると考えられる。ただし、実測値が小さい場合に大きな誤差となっている物が少数ではあるが存在しており、これらの誤差は許容できる範囲を超えている物と考えられる。大きな推定誤差となった検証用画像とその実測値(図 5 の破線内の 5 つのデータの入力画像)を図 6 に、推定誤差が小さかった画像の検証用画像とその実測値を図 7 に示す。推定誤差が大きい結果となった画像は誤差の小さかった画像と比べて画像内に輪郭を確認出来ないものが多く、実測値 360A の画像については人の目で見た場合には単色にしか見えないようなものもある。これらの推定誤差の大きな画像は屋内の床面の画像であり、教師データとしても枚数が少なかったために正しい推定結果を得られなかったものと考えられる。

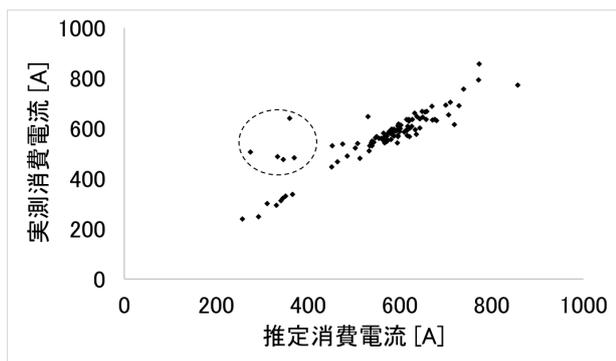


図 5 検証用画像での推定結果

Figure 5 Estimation results for validation images.



図 6 推定誤差の大きい画像の例

Figure 6 Images of Large Estimate Error.



図 7 推定誤差の小さい画像の例

Figure 7 Images of small estimate error.

4. 考察

4.1 実験結果

電動車いす移動時の消費電流値を出力とした推定モデルを深層学習によって作成し、その推定精度を検証用画像によって確かめた。推定精度は平均で 6.5%であったが、一部で大きな誤差となるものもあった。推定誤差の大きなもの（図 6）は、全て屋内の床面の撮影画像であり、これらの画像を除いた場合の推定誤差は 5.3%であり、全体としては高い精度での推定を行えているものと考えられる。屋外の路面画像については高い精度での推定を行えていることから、本研究の手法は屋外の路面については問題なく適用できる可能性があるものと考えられる。一部の大きな推定誤差となった画像は屋内床面の画像であったが、誤差を大きくした原因として、教師データ（屋内床面画像）の不足、光の反射による画像の不鮮明化といったことが考えられる。

屋内床面の教師データを増やした場合に推定精度の向上を期待できるかを確認するために、図 6 の 5 枚と同じ材質の床面画像を撮影し、それら画像の輝度値を -25~+25 の範囲で調整した画像を各 50 枚ずつ生成し、これを含めたデータで再度学習を行った。図 5 と同じ検証用画像で推定値と

実測値を比較したものを図 8 に示す。図 5 において大きな誤差であったデータのうち、実測値が 275A のものと 360A のもの（図 6 の 275 と 360 の画像）については、誤差が小さくなっている。しかし、全体的には推定精度が下がっており、特に消費電流を多く必要とする路面の画像の推定値が小さくなっている。このことから、推定精度が低い材質の画像の類似の床面のデータを多く用意して学習を行うことで推定精度の低いものについては精度の向上を期待できる。しかしながら、教師データの追加によって精度を下げることもあるため、加工した教師データを生成して利用する場合には、他の画像の学習結果に影響を及ぼさないように注意する必要がある。

光の反射による画像の不鮮明化については、撮影を行うカメラをより高性能なものに変更することや、赤外線カメラによる撮影画像を利用する等といった解決策が考えられる。ただし、今回はカラー画像を教師データとした学習を行っており、路面の色情報が重要であった場合には赤外線カメラの撮影画像を教師データにした場合に、正しい推定を行えない可能性もある。赤外線画像での深層学習による推定精度の検証については今後の課題である。

今回の検証において大きな誤差となったものは屋内のビニール材質の床面の画像であり、屋外については高い精度での推定を行っていた。画像からの推定を行う本研究の利用範囲を屋外に限定するのであれば、十分に許容できる範囲の精度での電動車いす移動時の消費電流推定を行える可能性があるものと考えられる。

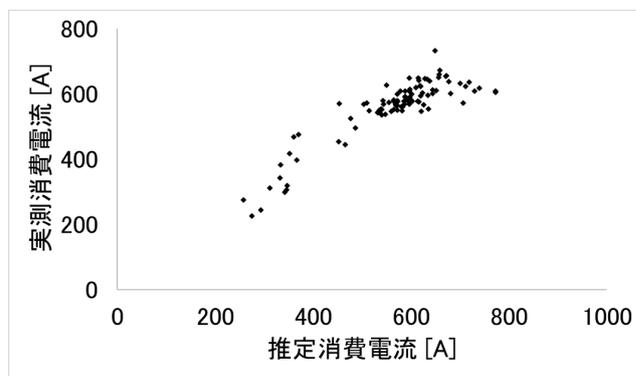


図 8 輝度調整済み画像追加モデルでの推定結果

Figure 8 Estimation results with brightness-adjusted image addition model.

4.2 本研究の応用

実験の結果、屋外の路面に限定した場合には約 5.3%の誤差で検証用データの推定を行えることを示した。このことから、電動車いすで路面を移動した際の消費電流値を路面画像からの推定は高い可能性で実現できるものと考えられる。また、本研究で深層学習の出力値とした電動車いす移動時の消費電流は、手動車いす移動時に必要とする仕事量

に換算可能であり[19]、路面画像からの推定結果を手動車いす向けの経路探索やバリアフリーマップのデータとして利用することもできる。また、今回は電動車いすの消費電流値の推定を行ったが、電動車いす移動時にかかる負荷に応じて増加する指標、例えば、路面の摩擦係数や材質の推定であれば同様の推定は行える可能性は高い。ただし、路面の摩擦係数や材質の推定を行う場合には、路面の凹凸やひび割れ、数ミリメートル程度の小さな段差については別途評価する必要があるため、経路探索に利用するための推定値としては動車いすの消費電流値や車いす移動時のトルク等の推定が適しているものと考えられる。

また、路面の画像から電動車いす移動時の消費電流の推定を行えたことから、路面の摩擦係数や材質、1cm以上の大きな段差、通路の幅、路面上の障害物の有無など、様々な情報を画像認識によって推定できる可能性があるものと考えられる。画像認識による推定が許容できる精度で可能なものについては、専用のセンサを必要とすることなく計測を行えるため、計測装置の大幅なコスト軽減を行える可能性があり、効率的な経路探索向けのデータ収集において有用と考えられる。

4.3 実用的な応用に向けた課題

本研究の実用的な応用については、いくつかの解決すべき課題が挙げられる。まず、検証に用いた画像は教師データ作成に用いたカメラと同じカメラで撮影した画像であり、異なるカメラで撮影した場合に正しい推定を行えるかについては未検証である。実用的な利用を目的とする場合には、汎用的に扱えるモデルでなければならないため、複数のカメラで同じ路面を同時に撮影して、それらを教師データとするなど、カメラの種類によらない推定を行えるモデルを作成する必要があるものと考えられる。また、教師データにないパターンでの画像の推定を行えない問題もある。教師データとした路面の画像に近い材質の推定は問題なく行えても、未知のデータの推定を正しく行うことは不可能と考えられる。これについての解決方法はなく、教師データを網羅的に用意したうえで、未知の材質についての誤差を許容するといった対応をする他ない。車いす使用者に経路を提示するにあたって、本来移動できない場所を移動可能と推定することは避けなければならないため、高い精度での推定が可能であるとしても、深層学習による推定結果を実用とするためには、慎重な検討が必要と考えられる。しかしながら、撮影画像のみで路面の微細な形状の差によって変わる指標を推定することは、バリアフリー情報の収集や経路探索システムのためのデータ収集のコスト低減のために非常に有効な手段であり、今後も実用可能なモデルの作成や実用範囲の検討等を進めていく予定である。

5. おわりに

本研究では、車いすによって路面を移動した際の負荷を高精度かつ簡便に計測するための手法の一つとして、深層学習によって路面画像から電動車いすの消費電流値を推定する手法を試みた。撮影した路面画像の位置を通過する際の電動車いすの消費電流値を計測し、ラベル付きの教師データ画像として深層学習による回帰推定学習を行った。作成した消費電流推定モデルを用いて検証用画像 100 枚の推定結果を検証した結果、屋外の路面画像においては平均約 5.3%の精度によって電動車いす移動時の消費電流値を推定することができた。実用的に利用可能なモデルとするためには、より多くの教師データによる学習が必要となるが、単眼カメラのみによって車いす移動時の負荷を推定できる可能性を示せたことは、効率的な路面情報収集において大いに価値のある結果と考えられる。

今後は、赤外線カメラ等も含む複数のカメラによって撮影した画像をもとに学習したモデルによる推定精度を検証するとともに、未知のデータの推定に課題を残す本手法を有効に活用可能な範囲を検討し、本研究の成果の実用的な応用を目指す予定である。

参考文献

- [1] 杉山郁夫, 土井健司, 若林仁, 川俣智計: 移動の質の定量化にもとづく歩行空間の評価方法に関する研究, 土木学会論文集, No.800, pp.37-50(2005).
- [2] 土井健司, 長谷川孝明, 小林成基, 杉山郁夫, 溝端光雄: 超高齢化を迎える都市に要求される移動の質に関する研究, IATSS Review, Vol.35, No.3, pp.38-49(2011).
- [3] H. Matthews, L. Beale, P. Picton and D. Briggs.: Modelling Access with GIS in Urban Systems (MAGUS), capturing the experience of wheelchair users. Area 35 (1): pp.34-45(2003).
- [4] 岡本耕平, 奥貫圭一, 森田匡俊: ハンディキャップを考慮した経路情報提供の試み, 名古屋大学文学部研究紀要, Vol. 50, pp.71-84(2004).
- [5] Sobek, A. D., and H. J. Miller.: U-access: A web-based system for routing pedestrians of differing abilities. Journal of Geographical Systems, vol.8, pp.269-287(2006).
- [6] P. Kasemsuppakorn and H. A. Karimi.: Data requirements and a spatial database for personalized wheelchair navigation, In Proceedings of the 2nd International Convention on Rehabilitation Engineering & Assistive Technology, pp.269-287(2008).
- [7] P. Kasemsuppakorn and H. A. Karimi.: Personalised routing for wheelchair navigation. Journal of Location Based Services Vol.3, No. 1, pp.24-54(2009).
- [8] 山本浩司, 安村禎明, 片上大輔ほか: ユーザの投稿情報に基づく経路ナビゲーション, The 18th Annual Conference of the Japanese Society for Artificial Intelligence, pp.1-4 (2004).
- [9] 井上道哉, 古山宗亮, 金房雄一, 長沢可也, “iPhone を利用したバリア情報記録・公開システム,” 電子情報通信学会技術研究報告, 福祉情報工学, vol.111, No.424, pp.97-101(2012).
- [10] C. Menkens, J. Sussmann, M. Al-Ali, E. Breitsameter, J. Frtunik, T. Nendel and T. Schneiderbauer.: EasyWheel-A Mobile Social Navigation and Support System for Wheelchair Users, In

Proceedings of the 2011 Eighth International Conference on Information Technology:New Generations, pp.859-866 (2011).

- [11] 国土交通省, バリアフリー経路探索体験サイト,
http://www.hokoukukan.jp/barrierfree_taiken.html
- [12] 牧恒雄, 竹内康, 松田誠: 歩道の凹凸評価方法に関する研究, 舗装工学論文集, Vol.1, pp.151-158 (1996).
- [13] 岡村美好, 深田直紘: 車いすの振動加速度を用いた歩道路面凹凸の評価に関する研究, 舗装工学論文集, Vol.9, pp.17-23(2004).
- [14] Ishida, T., Takemoto, H., Ishida, S., Kameyama, S., Himeno, K. and Kashima, S.: Evaluation of sidewalk unevenness based on wheelchair traveling resistance, Transportation Research Record: Journal of the Transportation Research Board, Vol.1956, pp.68-75(2007).
- [15] 金野僚一, 鈴木昭二: シニアカーのための測域センサを利用した路面の凹凸検出手法, ロボティクス・メカトロニクス講演会講演概要集, Vol.2010, ROMBUNNO.2A2-D14(2010).
- [16] 井上道哉, 古山宗亮, 金房雄一, 長沢可也: iPhone を利用したバリア情報記録・公開システム, 電子情報通信学会技術研究報告. WIT, 福祉情報工学, Vol.111, No.424, pp.97-101(2012).
- [17] 隅田康明, 合志和晃, 松永勝也, 志堂寺和則: 車いす使用者向け経路探索のための路面の傾斜および段差測定システムの開発, 電子情報通信学会技術研究報告, 福祉情報工学, Vol.114, No. 357, pp. 63-68(2014).
- [18] 隅田康明, 林政喜, 合志和晃, 松永勝也: 経路探索用データ作成のための電動車いすの走行負荷にもとづく手動車いすでの移動に必要な力量の推定方法, 情報処理学会論文誌, Vol.54, No.1, pp. 146-155(2013).
- [19] 隅田康明, 林政喜, 合志和晃, 松永勝也: 車輪付き手動移動体の走行負荷に基づく歩道の評価方法, 情報処理学会論文誌, Vol.57, No.1, pp. 1-10(2016).
- [20] 重村知輝, 野村泰稔: 深層学習に基づく物体検出・認識技術を用いた二段階構造表面ひび割れスクリーニング, 材料, Vol.69, No.3, pp. 218-255(2020).
- [21] 志賀純貴, 江本久雄, 馬場那仰, 吉武俊章: AI による変状抽出機能の舗装路面簡易評価システムへの適用, AI・データサイエンス論文集, Vol.1, No.1, pp. 180-189(2020).
- [22] 中村俊介, 駒田匡史, 松下光次郎, 松村雄一, 石崎 啓祐: 深層学習による路面画像を用いた路面入力騒音の予測, 自動車技術会論文集, Vol.50, No.5, pp. 1421-1426(2019).
- [23] ImageNet, <http://www.image-net.org>, Stanford Vision Lab, Stanford University, Princeton University (ref 2021-02-07).
- [24] Xception: Deep Learning with Depthwise Separable Convolutions, Cornell University, <https://arxiv.org/abs/1610.02357> (ref 2021-02-07).