

個人差を考慮した歩き方からの手荷物の重さ推定の検討

水野雅也[†] 川西康友^{††} 出口大輔[†] 村瀬 洋[†]

[†] 名古屋大学 大学院 情報学研究科 〒464-8601 愛知県名古屋市千種区不老町

^{††} 理化学研究所ガーディアンロボットプロジェクト 〒619-0088 京都府相楽郡精華町光台 2-2-2

E-mail: [†]mizunom@vislab.is.i.nagoys-u.ac.jp, ^{††}yasutomo.kawanishi@riken.jp, ^{†††}{ddeguchi,murase}@nagoya-u.jp

あらまし ロボットによる支援の1つとして、重い手荷物の運搬支援が考えられる。適切な人に適切なタイミングで支援するためには、実際の重さ（物理的重さ）だけでなく、その人がどのくらい重く感じているか（主観的重さ）を推定することが重要である。本研究では手荷物の重さが所持者の歩行時の様子に影響を与えることに着目し、歩行の様子を表現した3D人物骨格系列からの手荷物の物理的重さと主観的重さの推定を目的とする。所持者の姿勢は手荷物の重さだけでなく所持者の体格や歩行の癖などの身体特徴の違いによっても大きく変化するうえ、同じ重さの手荷物でも、体格の違いなどから人によって重さの感じ方は異なる。この問題に対して、人物骨格系列から身体特徴と、身体特徴を排除した標準化動作特徴をそれぞれ求め、特徴を重さの種類に応じて適切に重み付けすることで、身体特徴の違いを考慮した手荷物の物理的重さと主観的重さの推定手法を提案する。実験により、個人差を考慮しない手法と比較して高精度な結果を示した。

キーワード 手荷物重さ認識, 人物骨格系列, 身体特徴, グラフ畳み込み

1. はじめに

近年、見回りロボットが様々な場所で利用されるようになってきた[1], [2]。人と共存するロボットには、見回りだけでなく、観測した周囲環境の情報をもとに自主的に人を支援する能力が求められる。本発表では、このような支援の一つである、手荷物を重そうに持っている人を自主的に支援することに着目する。

手荷物を重そうに持っている人を自主的に支援するためには、手荷物を持てるロボットを開発する必要もあるが、支援を行なうかの判断能力を持たせることも必要である。手荷物の重さがロボットの持てる最大重量を超えてしまっている場合は支援できない。さらに、人が支援を必要としていないにもかかわらずロボットが支援をしてしまうと、その人がロボットの存在を煩わしく感じる恐れがある。人がロボットに煩わしさを持つようでは、人とロボットが信頼関係を築けず、ロボットが人に受け入れられない。これを避けるためには、支援を必要としていない人のみを見極め、適切なタイミングで支援する必要がある。

上述の見極めのためには、実際の重さだけでなく、人が手荷物をどの程度重く感じているかを推定する必要がある。本発表では、実際の重さのことを物理的重さ、どの程度重く感じているかを主観的重さと定義する。物理的重さが推定できればロボットが持てる重さを判断でき、主観的重さが推定できればその人にロボットによる支援が必要かどうかを判断できる。

手荷物の物理的重さによる負荷が人の歩行に与える影響を調査した論文[3]では、手荷物の物理的重さが大きくなると、骨盤傾斜が大きくなり、これが歩行に影響を与えることが示されている。また、主観的重さは物理的重さに影響を受ける。例えば、物理的重さが大きければ主観的重さも大きくなる。このこ

とから、主観的重さも歩き方に影響を与えるといえる。以上より本研究では、歩き方に着目して手荷物の物理的重さと主観的重さを推定する。しかし、歩き方は手荷物の物理的重さだけでなく所持者の体格や体重、歩き方の癖といった身体特徴の違いから生じる個人差によっても大きく変化する。論文[3]では、手荷物の物理的重さが所持者の体重の15%を超えると歩行効率が低下することが示されている。

歩き方は骨格の時間変化に表れる[4]。骨格の時間変化は、周囲や本人の見えの違いに頑健なため、行動認識等で注目されている[5]~[7]。そのため、手荷物の物理的重さと主観的重さの推定にも歩き方の表現として歩行時の骨格の時間変化を用いた行動認識手法を応用できると考えられる。しかし骨格の時間変化を用いた行動認識手法は、個人差を吸収するように学習されるため、個人差を考慮する必要がある手荷物の物理的重さや主観的重さは推定には適さないと考えられる。

この問題に対し、本研究では、歩行時の骨格の時間変化で表現された歩き方の特徴を、個人差を表す身体特徴と、個人差を吸収した標準化動作特徴に分離して手荷物の重さの推定に活用する手法を提案する。身体特徴とは体格や歩き方などの人の属性を表現することを目的とした特徴であり、標準化動作特徴とは歩き方の特徴から身体特徴を排除したものである。主観的重さでは個人差は吸収するべきであり、物理的重さでは個人差を考慮すべきであるため、歩き方の特徴を、“個人差を表す身体特徴”と“身体特徴を排除した標準化動作特徴”に分離したうえで、これらの特徴を重さの種類によって選択的に利用して推定する枠組みを提案する。

以下、2節で関連研究について述べる。次に、3節で手荷物の物理的重さと主観的重さの推定手法について述べる。さらに、

4 節で実験とその評価について述べる．最後に，5 節でまとめと今後の課題について述べる．

2. 関連研究

2.1 重さ推定の研究

手荷物の重さを推定するために，身体動揺を用いる研究 [9] がある．身体動揺とは，直立して静止していても体に生じるわずかな揺れである．この研究では，手荷物の重さが重いほど大きくなるという身体動揺の特徴に着目して，手荷物の重さを推定する．この研究では，身体動揺を取得するために静止している人を頭上真上から撮影する必要があり，今想定しているようなロボットの視点からは観測が難しい．また，身体動揺は静止していないと計測できない．

物体の重さ推定手法として，持ち上げ動作を利用する研究 [10] がある．この研究では，物体の重さによって持ち上げるときの手の動きが変化することに着目し，この時の手の動きから物体の重さを推定する．しかし，実用の際には物体を持ち上げる瞬間を撮影する必要があり，利用できる状況が限定される．

2.2 骨格系列を利用した認識研究

骨格系列を利用した研究として，歩行に動きの属性を付与する研究 [4] がある．この研究では動きの属性にオノマトペを採用している．LSTM を用いて，歩行の様子を表現するオノマトペを歩行時の骨格系列から推定している．LSTM は時間的特徴を考慮した認識や推定ができるため，骨格系列を利用した行動認識でも利用されている [5]．

近年は骨格系列をグラフとしてとらえるグラフ畳込みが主流になっている．グラフを利用した骨格系列からの行動認識研究として ST-GCN [6] がある．この手法は骨格構造に従ったグラフを利用し，各フレームに対してグラフ畳込みを行って空間的特徴を抽出し，その後各関節点に対して時間方向の畳込みを行って時間的特徴を抽出する．この手法により，骨格構造を考慮した認識を実現している．また，ST-GCN を発展させた手法として MS-G3D [7] がある．この手法では，空間的な接続がある関節を全フレームに亘って接続することで作成した時空間グラフを用いてグラフ畳込みを行なう G3D に加え，注目関節点からのホップ数ごとに空間グラフを作成して複数スケールの畳込み込みをする仕組みを組み合わせた手法である．この手法により，骨格構造的に離れているが認識に重要な意味を持つ関節点同士を直接接続できる．ST-GCN を発展させた別の手法として STA-GCN [8] がある．この手法では，フレームごとに関節の重要度を表す Attention node と，動作ごとに関節間の関係性を表す Attention edge を獲得し，これによって構成されたグラフを用いてグラフ畳込みを行う．この手法により，動作ごとに異なる関節間関係性を考慮できる．

3. 手荷物の物理的重さと主観的重さ推定

3.1 提案手法の概要

本研究では，歩行時の骨格変化として 3D 人物骨格系列を利用する．3D 人物骨格系列はカメラ座標系における関節点の (X, Y, Z) 座標の集合である．また，歩行は 2 歩の繰り返しであ

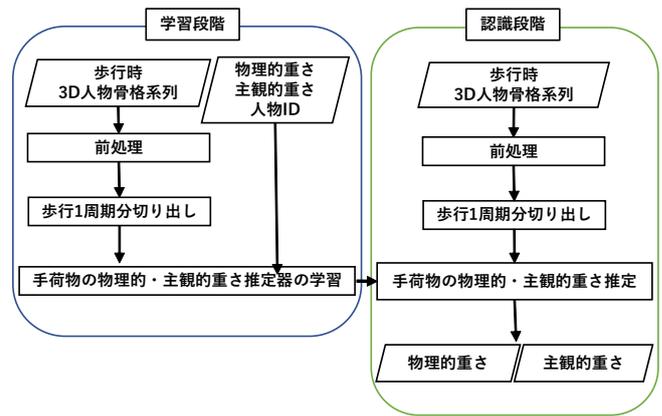


図 1: 提案手法の処理手順

ることに着目し，2 歩分を歩行 1 周期とする．本項では，歩行 1 周期分の 3D 人物骨格系列により表現された歩行時の姿勢から，手荷物の物理的重さと主観的重さを回帰で推定する手法について述べる．図 reffig:process に提案手法の処理手順を示す．提案手法ではまず，歩行時の 3D 人物骨格系列を入力とする．次に，歩行時の 3D 人物骨格系列に対して前処理を行う．そして，そこから歩行 1 周期分の 3D 人物骨格系列 X を切り出す．最後に， X を手荷物の物理的・主観的重さ推定器に入力し，手荷物の物理的重さと主観的重さの推定結果を得る．

以下ではまず，手荷物の物理的重さと主観的重さ推定器の構成について述べる．次に，歩行 1 周期分の 3D 人物骨格系列 X に対して行う前処理について述べる．最後に，本手法で利用する 2 つの特徴抽出モジュールについて述べる．

3.2 手荷物の物理的重さと主観的重さ推定器の構成

提案手法では，歩行 1 周期分の 3D 人物骨格系列から身体特徴抽出モジュールを用いて身体特徴を抽出し，標準化動作特徴モジュールにより標準化動作特徴を抽出する．そして，重さの種類に応じて利用する特徴を選択し，物理的重さと主観的重さを推定する．これにより，物理的重さ推定では個人差を考慮した推定を，主観的重さ推定では個人差を吸収した推定ができる．

図 2 に物理的重さと主観的重さ推定器の構造を示す．まず，歩行時の 3D 人物骨格系列 X から，身体特徴抽出モジュールにより身体特徴 x_p を，標準化動作特徴抽出モジュールにより標準化動作特徴 x_m を抽出する．次に，各重さ推定に利用する特徴を選択する．物理的重さ推定では，身体特徴と標準化動作特徴を連結した特徴 $[x_p, x_m]$ を利用する．また，主観的重さ推定では，標準化動作特徴 x_m を利用する．最後に，各重さを推定する．物理的重さ推定では， $[x_p, x_m]$ を物理的重さ推定器 g_p に入力し，物理的重さ推定結果 $\hat{y}_p = g_p([x_p, x_m]; \theta'_p)$ を得る．主観的重さの推定では， x_m を主観的重さ推定器 g_s に入力し，主観的重さ推定結果 $\hat{y}_s = g_s(x_m; \theta'_s)$ を得る． θ'_p, θ'_s は学習により決定する． g_p と g_s は共に 2 層の全結合層で構成する．中間層と出力層の活性化関数には Leaky ReLU を用いる．物理的重さ推定器と主観的重さ推定器の構造を図 3 に示す．

学習では，推定した各重さと正解値の差に基づく誤差 L を求める．

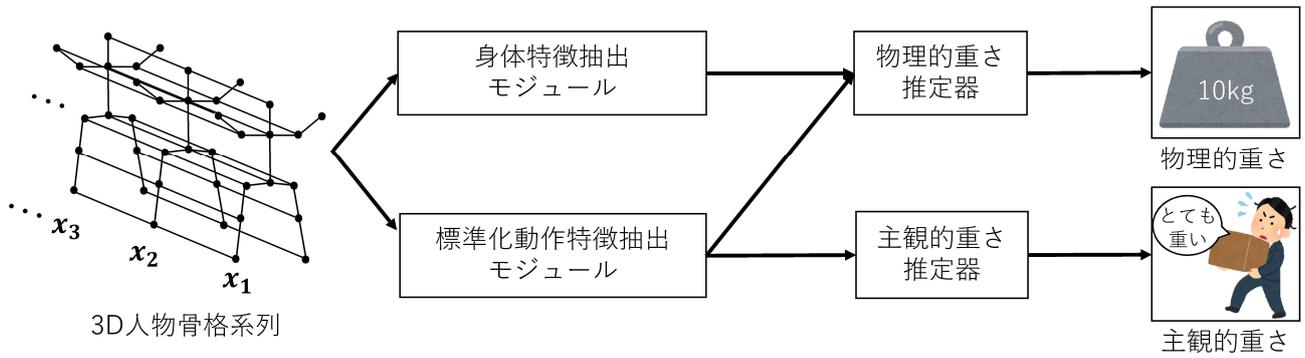


図 2: ネットワーク構造

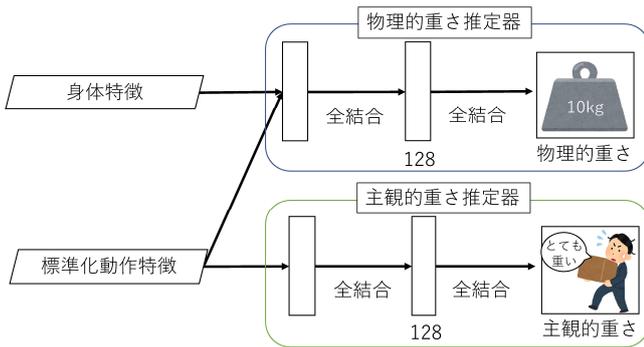


図 3: 物理的長さ推定器と主観的長さ推定器の構造

$$L = L_p + L_s \quad (1)$$

L_p は物理的長さの平均二乗誤差であり L_s は主観的長さの平均二乗誤差である。さらに、 L に後述する各モジュールで計算する誤差 L_t, L_o を追加した L_a を最小化するように誤差逆伝播法によりネットワークの重みを更新する。

$$L_a = L + L_t + L_o \quad (2)$$

3.3 前処理

提案手法では、歩行時の 3D 人物骨格系列に対して前処理を行う。まず、人の位置やスケール、向きによる影響を排除するため、 X の正規化を行なう。まず、3D 人物骨格系列の全フレームにおいて、腰関節の座標が $(0, 0, 0)$ となるように平行移動をして位置を正規化する。次に、3D 人物骨格系列のすべてのフレームにおいて、腰関節から首関節までの距離が 1 になるようにすることでスケールを正規化する。最後に、左腰関節点と右腰関節点が (x, z) 平面上で x 軸と平行になるように回転させることで向きを正規化する。

次に、歩行時の人物骨格系列から歩行 1 周期分の 3D 人物骨格系列 X を切り出す。切り出しは、左足関節点と右足関節点の奥行き方向の座標の差が極大となる点を基準として行なう。

最後に、歩行 1 周期分の 3D 人物骨格系列はそれぞれ系列長が異なるため、系列から等間隔に M フレーム抜き出すことで固定長とする。

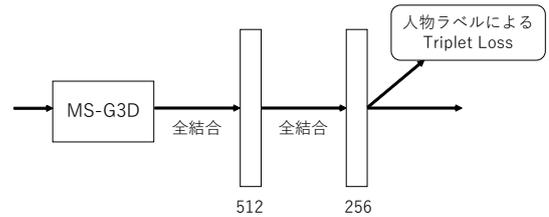


図 4: 身体特徴抽出モジュールの構造

3.4 特徴抽出モジュール

3.4.1 身体特徴抽出モジュール

身体特徴は人ごとに異なると考え、身体特徴抽出モジュール特徴を人ごとに分離できるように学習する。ここでは、歩行 1 周期分の 3D 人物骨格系列 X を MS-G3D のネットワーク f_p に入力することで身体特徴 $x_p = f_p(X; \theta_p)$ を得る。このとき、身体特徴 x_p に対して、人を区別できるように人物ラベルによる式 (3) の Triplet Loss を導入する。

$$L_t = [d_p - d_n + \alpha]_+ \quad (3)$$

$$[z]_+ = \max(0, z)$$

d_p は、ある 3D 人物骨格系列 X^{A_1} から抽出した身体特徴 $x_p^{A_1}$ と、同一人物ラベルの別の 3D 人物骨格系列 X^{A_2} から抽出した身体特徴 $x_p^{A_2}$ の距離 $|x_p^{A_1} - x_p^{A_2}|$ で、 d_n は、別の人の 3D 人物骨格系列 X^B から抽出された身体特徴 x_p^B との距離 $|x_p^{A_1} - x_p^B|$ である。また、 α はマージンを定める定数である。本実験で使用する身体特徴抽出モジュールの構造を図 4 に示す。中間層の活性化関数には Reaky ReLU を用いる。

3.4.2 標準化動作特徴抽出モジュール

標準化動作特徴抽出モジュールでは、出力する標準化動作特徴が人を区別できない特徴になるよう学習する。まず、歩行 1 周期分の 3D 人物骨格系列 X を MS-G3D に基づくネットワーク f_m に入力することで標準化動作特徴 $x_m = f_m(X; \theta_m)$ を得る。この x_m を、Gradient Reversal Layer [11] を通して人物ラベル推定器 h に入力する。Gradient Reversal Layer とは、誤差逆伝搬時に、前の層に伝わる勾配の符号を反転させる層である。これにより、標準化動作特徴が人を区別できないような特徴になるように、つまり身体特徴を除いた特徴になるように学習でき

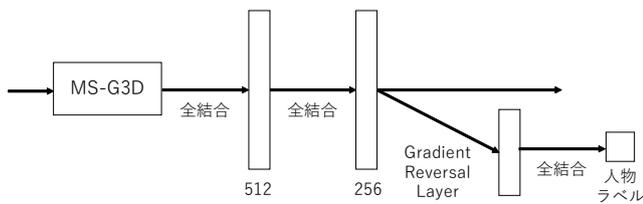


図 5: 標準化動作特徴抽出モジュールの構造

る．標準化動作特徴抽出モジュールを図 5 に示す．中間層の活性化関数は Reaky ReLU を用いる．このとき，人物ラベル推定器はクロスエントロピー誤差 L_o を用いて学習する．

4. 実験

4.1 データセット

歩行時の人の様子を撮影し，その人の手荷物の物理的重さと主観的重さを真値として付与した公開データセットはないため，本研究では実験用データセットの撮影を行った．本節ではデータセットを構築した際の撮影条件及びその内容について述べる．

本研究では，1 人の歩行者が 1 つの手荷物を持って歩いている状況を想定する．実験参加者に手荷物を所持して歩かせ，その様子を高さ 2m の位置に設置した Microsoft 社製の Azure Kinect センサで撮影することで 3D 人物骨格系列を取得した．実験環境を横から見た図を図 6 に示す．また，撮影した画像と 3D 人物骨格の例を図 7 に示す．Azure Kinect SDK により取得できる 3D 人物骨格はカメラ座標系における関節点の (X, Y, Z) 座標の集合であるが，本研究では，カメラから降ろした垂線と床面との交点を原点とし，床面が水平となる ($y = 0$) ように設定した世界座標系に変換して用いた．3D 人物骨格系列の系列長 $M = 25$ とした．

データセット撮影のために，被験者として 8 名（男性 7 名，女性 1 名）用意した．また，手荷物の種類は，手提げ鞆，肩さげ鞆，リュックサック，段ボール，買い物かごとし，手荷物の内容量は，0kg, 5kg, 7.5kg, 10kg, 12.5kg, 15kg とした．内容量は重りで調整した．主観的重さの正解値は，アンケート調査により収集した．アンケートは，0 点を何も持っていない状態，100 点を 20kg の手提げ鞆を所持したときに感じる重さとし，各手荷物を持った歩行の後に点数をつけさせた．このとき，物理的重さの正解値を知ることが主観的重さに影響しないように，所持する手荷物の中身は被験者に見えないようにした．さらに，前の系列の撮影で所持した手荷物の重さによる影響をなくすため，撮影ごとに 5 分程度の休憩をとった．この実験により，1 被験者につき 30 パターンの歩行時の 3D 人物骨格系列を撮影した．また，全実験参加者は撮影データの研究目的での利用・公開に同意した．

4.2 実験手順

本実験では，手荷物の種類ごとに物理的重さと主観的重さの推定を評価する．評価実験の評価指標として，推定結果に対して平均誤差 M_p を用いる．

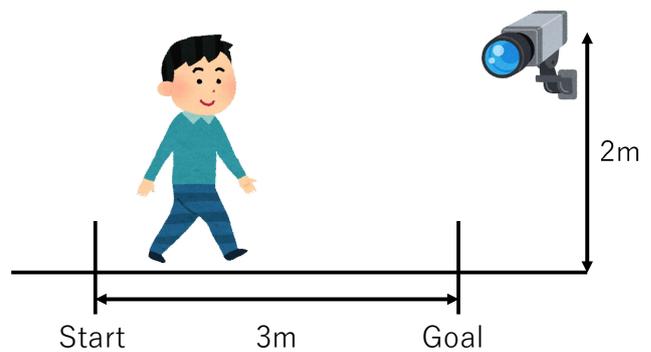


図 6: 撮影環境を横から見た図

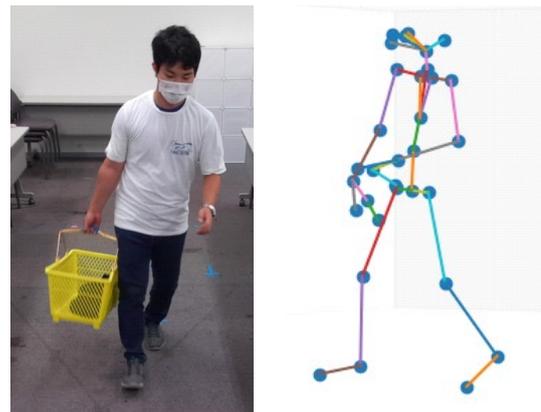


図 7: 撮影画像と 3D 人物骨格の例



図 8: 実験に使用した手荷物の例

$$M_p = \frac{1}{N} \sum_{n=1}^N |y_p - \hat{y}_p| \quad (4)$$

ここで， N は評価データ数を表し， y_p と \hat{y}_p はそれぞれ評価データにおける物理的重さ又は主観的重さの真値と推定値を表す．本実験ではデータセット中の 8 人の被験者のうち，1 人を評価用，7 人を学習用として Leave-one person out により精度を求めた．提案手法における 3D 人物骨格系列からの特徴を身体特徴と標準化動作特徴へ分離することによる効果を確認するため，提案手法を MS-G3D のみから物理的重さと主観的重さ

表 1: 各手荷物種類での物理的重さ推定値の真値との平均誤差 (kg)

	手提げ鞆	肩さげ鞆	リュックサック	段ボール	買い物かご	平均
比較手法	3.78	2.96	3.56	3.91	2.90	3.42
提案手法	3.65	3.29	3.18	3.54	2.64	3.26

表 2: 各手荷物種類での主観的重さ推定値の真値との平均誤差 (kg)

	手提げ鞆	肩さげ鞆	リュックサック	段ボール	買い物かご	平均
比較手法	19.63	11.51	13.39	19.83	14.18	15.71
提案手法	19.04	11.79	13.65	17.31	13.53	15.06

を推定する手法と比較した。データセットの歩行時の 3D 骨格系列から切り出した歩行 1 周期分の 3D 人物骨格系列は全体で 2,108 周期と少なかったため、データ拡張を行った。ここでは、人物骨格系列からランダムに 20 フレーム抜き出した。このとき、元の人物骨格系列での順序関係は保存する。この処理により人物骨格系列が等間隔でなくなるが、元の系列の大部分を利用するため、各隣接フレームの間隔に大きな違いはなく、この影響は小さい。この処理を各人物骨格系列に対して 100 回行うことで、データ量を 100 倍の 210,800 周期とした。

4.3 実験結果

表 1 に手荷物の物理的重さ推定値の真値との平均誤差を、表 2 に主観的重さ推定値の真値との平均誤差を示す。実験結果から、提案手法を用いることで、物理的重さ推定においては肩さげ鞆以外、主観的重さ推定においては肩さげ鞆とリュックサック以外のすべての手荷物で平均誤差が比較手法よりも小さい結果となった。

4.4 考察

表 1 に示したように物理的重さ推定ではほとんどの手荷物種類において比較手法よりも提案手法の方が高精度であることから、物理的重さ推定において、身体特徴と標準化動作特徴を分離することが有効であると分かった。また、表 2 に示したように主観的重さ推定でもほとんどの手荷物種類において比較手法よりも提案手法のほうが高精度であることから、標準化動作特徴のみを使うことで身体特徴の影響を小さくした推定が有効であると分かった。

一方で物理的重さ推定と主観的重さ推定の双方において、肩さげ鞆に対する推定精度が提案手法よりも比較手法のほうが高かった。この要因の一つとして、実験を行った際、数人の被験者から肩さげ鞆の肩掛け紐が肩に食い込んで痛かったという意見があった。一方で肩さげ鞆の肩掛け紐による痛みはあまり感じなかったという被験者もいた。肩さげ鞆の紐が肩に食い込んで痛かったと答えた被験者はその時の主観的重さを高く評価していた。このことから、肩さげ鞆での重さ推定においては肩掛け紐を痛く感じたかどうか影響したことが考えられる。提案手法では人物ラベルによる特徴抽出を行っており、一方で肩掛け紐を痛く感じるのは手荷物が重い場合のみであるため、肩

掛け紐を痛く感じるかの特徴は吸収されたと考えられる。そのため、肩さげ鞆においては比較手法のほうが高精度であったと考えられる。

また今回の実験では、主観的重さの基準として 100 点を 20kg の手提げかばん、0 点を何も持っていない状態、70 点を助けが欲しい程重く感じる状態として定義した。しかし、この指標には、20kg の手提げ鞆を持つという物理的な基準と、助けが欲しい程重く感じるという主観的な基準が混在している。これでは、物理的な基準と主観的な基準のどちらを重要視するか人によって点数のつけ方が変わってしまうと考えられる。また、主観的重さの基準として 20kg の手提げ鞆を 100 点としている。しかし、20kg の手提げ鞆の重さの感じ方は人により異なるので、2 人が同じ主観的重さ評価をしても、同じ程重く感じているとは言えない。以上より、今後主観的重さの基準は、「この重さなら 30 分程は所持したまま歩ける」などの主観的な基準として定義する方が良いと考えられる。

さらに今回の実験では、人ごとに身体特徴が違うという前提のもとに人物ラベルに基づいて身体特徴の抽出や排除を行ったが、実際は身体特徴が似通った人もいれば大きく違う人もおり、人物ラベルだけで身体特徴を表すのでは不十分であると考えられる。そのため、人物ラベルだけではなく、身長や体重、握力などの身体特徴にかかわりがある特徴も利用して身体特徴の抽出や排除を行なう方が、良い特徴が得られる可能性がある。

最後に、今回の研究に使用した歩行時の 3D 人物骨格系列は Azure Kinect SDK を用いて推定したが、推定に失敗するケースがあった。これは、被験者が大きめの服を着用していたり、黒いマスクを装着していた場合などに多く見られた。実用の際は、このような推定に失敗した 3D 人物骨格系列を使用しないようにするシステムが必要であると考えられる。

5. おわりに

自主的に人を支援するロボットが求められており、その一つとして手荷物を重そうに持っている人を自主的に支援することが挙げられる。この支援を行うか否かの判断材料として、手荷物の実際の重さである物理的重さと、どのくらい重く感じているかを表す主観的重さの推定が必要である。本研究では、手荷

物の重さが人の歩行時の様子に影響を与えることに着目し、歩き方の特徴から手荷物の物理的重さと主観的重さを推定する手法を提案した。しかし、歩き方は人の体格などによって大きく変化しうるうえ、同じ重さの手荷物でも体格の違いなどから人によって重さの感じ方が異なる。この問題に対して、歩き方の特徴から身体特徴と身体特徴を除いた特徴である標準化動作特徴をそれぞれ求め、重さの種類に応じて特徴を選択することで身体特徴の違いを考慮した物理的重さと主観的重さを推定する手法を提案した。

今後の課題として、主観的重さの評価指標の見直し、身体特徴の類似性に着目した推定が挙げられる。

謝 辞

本研究の一部は JSPS 科研費 (17H00745) による。

文 献

- [1] Amazon Staff, "Amazon Device & Services news September 2021," Amazon, <https://www.aboutamazon.com/news/devices/amazon-devices-services-news-september-2021>,
- [2] 湯口 彰重, 河野 誠也, 石井 カルロス 寿憲, 吉野 幸一郎, 川西 康友, 中村 泰, 港隆 史, 斉藤 康己, 美濃 導彦, "ぶつくさ君: 自身の外界認識と内部状態を言語化するロボット", 第 39 回日本ロボット学会学術講演会予稿集, Sep. 2021.
- [3] E. Hyung, H. Lee, Y. Kwon, "Influence of load and carrying method on gait," Proc. Gait and Posture, Vol.22, no.1, pp.63-68, Aug. 2005.
- [4] 加藤 大貴, 平山 高嗣, 道満 恵介, 井手 一郎, 川西 康友, 出口 大輔, 村瀬 洋, "音象徴性を利用したオノマトペによる歩容の記述," 人工知能学会論文誌, vol.33, no.4, pp.B-HC2_1-9, Mar. 2018.
- [5] J. Liu, A. Shahroudy, D. Xu, G. Wang, "Spatio-Temporal LSTM with Trust Gates for 3D Human Action Recognition," Proc. of European Conference on Computer Vision, pp.816-833, Oct. 2016.
- [6] S. Yan, Y. Xiong, and D. Lin, "Spatial temporal graph convolutional networks for skeleton based action recognition," Proc. of the 32nd AAAI Conference on Artificial Intelligence, pp.7444-7452, Feb. 2018.
- [7] Z. Liu, H. Zhang, Z. Chen, Z. Wang, W. Ouyang, "Disentangling and Unifying Graph Convolutions for Skeleton-Based Action Recognition," Proc. of IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.143-152, June. 2020.
- [8] K. Shiraki, T. Hiraoka, T. Yamashita, H. Fujiyoshi, "Spatial Temporal Attention Graph Convolutional Networks with Mechanics-Stream for Skeleton-based Action Recognition" Proc. of the Asian Conference on Computer Vision, Nov. 2020.
- [9] 山口 優大, 神谷 卓也, 西山 正志, 岩井 儀雄, "身体動揺を用いた重量物所持の認識可能性の検証", ビジョン技術の実利用ワークショップ講演論文集, no.IS2-A1, pp.1-5, Dec. 2019.
- [10] 仲田 仁, 田村 仁, "持ち上げ動作からの所持物体の重量推定", 第 80 回全国大会講演論文集, vol.1, pp.435 - 436, Mar. 2018.
- [11] Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. Marchand, V. Lempitsky, "Domain-Adversarial Training of Neural Networks", J. of Machine Learning Research, vol.17, pp.1-35, May. 2016.