看護業務負担の定量的計測に向けたウェアラブル筋電位計測の基礎検証

宮本崇[1]　長谷川達人[1]

概要：看護の現場における業務には身体的負荷が大きいものが多いが，定量的な計測はできておらず各々の負荷量は個人の主観に依存している．現状，看護師の負担を把握するには各々の申告が必要だが，日々多忙な看護師にとって頻繁に負荷量を申告するのは手間であり，本来の業務の妨げとなる．本研究では，身体的負荷量を自動的に認識するシステムを提案する．提案手法では，ウェアラブルデバイスにより得られた筋電位をもとに機械学習により身体的負荷を推定する．特に本稿では，実験的に筋肉に負荷をかけた状態を段階的に検出できるのかという基礎検証を行った．身体的負荷推定に関わる因子を分析した結果，負荷量に応じて線形にデータが変化する傾向があることを確認した．

Effectiveness verification of wearable electromyography measurement toward quantitatively detecting burden of nursing work

TAKASHI MIYAMOTO[1]　TATSUHITO HASEGAWA[1]

1. はじめに

看護師は患者の状態を定期的に観察し，食事や身の周りの世話をし，昼夜問わず予期せず起こる緊急事態に注意しながら業務を行っている．看護の業務内容には肉体への負担が大きいものが多い．具体的には患者の体位変換やベッド環境の整備，清拭，排泄の介助などの病養上の世話が挙げられる．例のような身体的負担の大きい業務が，継続的に特定の看護師に集中してしまった場合，ストレスや過労の原因となり，職場への不満や離職，うつ病などに繋がる可能性がある．また，疲労の蓄積により注意が散漫になり，医療過誤に繋がる可能性がある．各看護師の身体的負荷を計測し，負荷が継続的にかかっている状態を把握することで，適切な人員配置の検討材料となることが期待される．

身体的負荷を推定する一例として，各看護師の業務内容を確認し，経験による予測をもとに業務による負荷量を予測する方法が考えられる．看護師はチャートやフローシートと呼ばれる文書に患者の観察結果や患者への処置内容を記録している．看護記録をもとに業務を把握する手法も考えられるが，記録された業務内容毎に一律の身体的負担量とは限らず，看護師自身が感じる身体的負荷量は同じ業務量でも各々の主観により異なり，定量的な計測もできていない．すなわち，同じ業務でも負担が大きいことや小さいことが様々であること，看護師自身の筋肉量や主観にも依存することから，看護記録をもとに負担を判断するには限界がある．現状は，看護師の感じる身体的負荷量を把握する方法は各看護師の申告に依存している．業務中に看護師自身が身体的負荷量を適宜申告することは手間の観点からも現実的ではない．患者への対応に追われている状態や，緊急事態の対処などを行っている状態では申告が適切に行われない可能性が考えられる．その場合，看護師の身体的負担を正確に把握することは難しい．

よって看護師による申告ではなく，機械的に自動で業務や身体的負担を検出させる技術が求められる．看護師業務を検出する方法の一つとして，カメラを用いた検出が考えられる．角ら[1]は固定カメラやマイクから得られたデータを自動的に整理し情報提示する手法を開発した．しかし，カメラを設置する際，機器のための空間を確保することや環境の整備が必要である．また，カメラでの検出は画角に映る障害物や病室の明るさなどの環境の影響を受けることが考えられる．カメラは定められた特定の空間での検出は容易だが，病院内を移動する看護師個人に対しての継続的な検出は容易ではない．加えてカメラに映らない業務を適切に検出することは難しい．また撮影によって看護師だけでなく患者のプライバシーも侵害される危険性がある．

他の方法として，ウェアラブルデバイスを用いた看護業務の検出がある．看護師にウェアラブルデバイスを装着させ，各々に対して業務を検出し身体的負荷量を推定する．個人ごとの継続的な検出が期待でき，得られた生データを用いることでプライバシー侵害のリスクもない．

本研究では，アームバンド型のウェアラブルデバイス Myo を用いて常時計測した筋電位をもとに，身体的負荷を推定する手法を提案し，その基礎検証を行う．本研究により，業務中の看護師の身体的負荷を定量的かつ自動的に記録することで，看護師の業務を可視化する．これまで業務内容の可視化は，各業務に費やした時間での調査が主であ

1 福井大学大学院工学研究科
Graduate School of Engineering, University of Fukui

ⓒ2019 Information Processing Society of Japan

り，実際の看護師の身体的負担を定量的に評価されたものはない．安全に看護が提供されるには，看護師への負担を可能な限り軽減し，患者への処置に集中できる環境づくりが重要である．自動的に作業内容を記録することで，看護師への負担を削減しつつ身体的負荷量を把握でき，最適な人員配置の検討に活かすことが期待される．

2. 関連研究

桑原ら[2]や井上ら[3]はウェアラブルセンサにより看護師の 1 日の行動を自動計測し，業務内容データを自動的に収集する手法を提案した．文献[2]では，体に音声入力用のマイク，姿勢の傾斜角センサ，万歩計を装着し，実際の医療現場において看護業務識別の有効性を示した．文献[3]では iPod touch に搭載された加速度センサと小型加速度センサを 3 つ看護師に装着させ，看護業務の識別を行った．

渡邊ら[4]は名刺型のセンサ端末を被験者に装着させ，加速度センサデータや人間同士の対面情報を収集した．装着したセンサから人間の行動を計測し，身体的な動きの度合いである活発度や対面コミュニケーションと生産性との関係を定量的に評価した．磯田ら[5]は，文献[4]で用いたセンサに加え，位置情報，看護師業務情報のデータも収集した．

これらの研究は看護師がどのような業務を行ったかを記録するもので，看護師が感じる身体的負荷を推定することはしていない．また，看護業務の妨げにならないように配慮しているが，文献[3]では装着するセンサが複数あり，文献[5]では装着されたセンサデータ以外のデータも用いている．より手軽に検出するためには，装着するセンサは小さく，かつ少ないほうが望ましい．

身体的負荷がかかることにより，筋疲労が蓄積すると考えられる．Kogi ら[6]は筋疲労実験で，表面筋電位のパワースペクトルは筋疲労につれて低域に成分が集中するように変化することを発見した．よって本研究では，筋電位を計測することで得られるセンサデータから身体的負荷を推定する着想に至った．

本研究のように，腕に装着したセンサから得られた筋電位を利用する研究として吉川ら[7]の研究がある．この研究は筋電義手の制御を目的としている．腕にウェアラブルデバイスを装着し，得られた筋電位から手の動作のリアルタイム識別手法を提案している．しかし，文献[2,7]はともにセンサを自作しており，外部の者が同様のデバイスを再現するのは容易ではない．

本研究の位置づけは，看護師自身が感じる身体的負荷を筋電位センサデータより定量的に推定することである．これまでは加速度センサを用い，看護業務を認識する研究はあったが，筋電位センサデータより身体的負荷を推定する研究は著者の調査の限り存在しない．筋疲労の蓄積を表面筋電位より直接計測することにより，加速度センサでの計測に比べ確実に身体的負荷を推定することが期待される．また，市販されたウェアラブルデバイスである Myo を計測機器とすることで，今後の現場への展開が現実的である．

3. 提案手法

3.1 概要

本研究ではアームバンド型ウェアラブルデバイスである Myo から簡易計測できる筋電位をもとに身体的負荷を推定する手法を提案する．身体的負荷が大きいほど筋肉は疲労すると考えられるため，疲労度合いを推定するために，ウェアラブルデバイスで計測できる筋電位を用いた．

提案手法の概要を図 1 に示す．本研究では，Myo を右手前腕部に装着し，得られた筋電位データから特徴量抽出を行う．抽出した特徴量を用いて，負荷がないリラックス状態と負荷をかけた 6 状態の計 7 状態に分類する．負荷をかけた 6 状態とは，負荷量が小，中，大の 3 カテゴリそれぞれに対し，動かしているか静止しているかの 2 状態に分けたものである．また，得られたデータを分析し，Myo で観測する筋電位情報と筋肉負荷の関連性を考察することで，今回計測していない負荷量の推定も実現可能か考察する．

3.2 使用機器

本研究では，身体的負荷を筋電位より推定するために計測デバイスとして Myo を採用した．Myo とは，表面筋電位

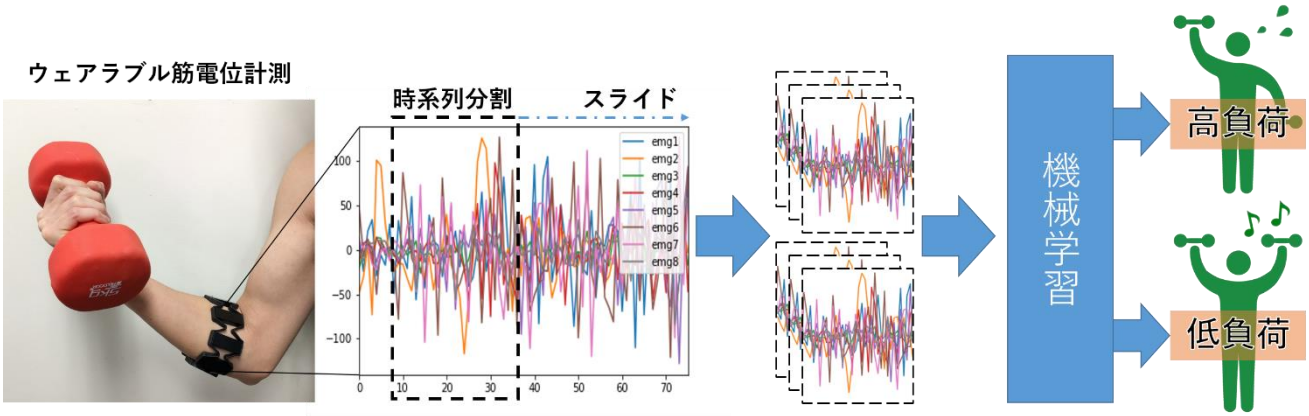

図 1　身体的負荷推定手法の概要図

ⓒ2019 Information Processing Society of Japan

や加速度などを簡易計測できるアームバンド型のウェアラブルデバイスである. 図 1 左の写真が Myo を着用して筋電位計測を行っている様子である．筋電位とは筋肉を動かす際に発生する生体電位のことである． Myo に搭載されたステンレス筋電センサは皮膚に直接触れており，皮膚表面から筋電位を計測する．ここで，皮膚表面から得られる筋電位は表面筋電位という．本デバイスから得られた筋電位データより, 手や指, 腕の動きを認識できる可能性がある．また，Bluetooth による無線接続により，スマートフォンや PDA に記録することができ, 病院内のような行動範囲が広い業務において看護業務を妨げない計測が可能である．また，Myo を直接前腕部に装着するため，カメラを用いる手法で課題であった棚やベッドなどの遮蔽物や勤務時間帯による明るさの変化などの環境による影響を受けない.

Myo には，3 軸加速度センサ，3 軸ジャイロスコープ，3 軸磁力計，ステンレス筋電センサが搭載されている．本研究では，ステンレス筋電センサを用いて表面筋電位データを取得する．このセンサは腕の周囲を巻くように 8 つ設置されている．ステンレス筋電センサのサンプリング周波数は 200Hz, その他のセンサのサンプリング周波数は 50Hz である.

3.3 特徴量抽出

機械学習を行うため，得られた筋電位データより特徴量抽出を行う．筋電位データを 128 サンプルごとのフレームで区切り，各フレームに対して特徴量の抽出を行う．抽出した特徴量を表 1 に示す．特徴量はフレーム内の筋電位データから, 時間領域と高速フーリエ変換（FFT）を施して求めた周波数領域の 2 領域に対して抽出する．時間領域に対しては，各センサの筋電位の最小値，四分位数，中央値，最大値，平均値，標準偏差，各センサ同士の相関係数の 84 種類抽出し, 周波数領域に対しては, 時間領域同様の 84 種類に各センサでの振幅が最大となる周波数の 8 種類を加えた 92 種類を抽出する．これを低周波数と高周波数それぞれに行い，計 184 種類を抽出する．両領域の合計 268 種類の特徴量を学習に用いる.

表 1　抽出した特徴量

時間領域	周波数領域	
最小値	最小値	各センサに対し
四分位数	四分位数	
中央値	中央値	
最大値	最大値	
平均値	平均値	
標準偏差	標準偏差	
-	最大値の周波数	
相関係数	相関係数	センサ同士

3.4 重要因子の探索

適切な機械学習を行うためには，学習に有効な特徴を適切に選択する必要がある．また，本稿では各特徴量と身体的負荷の関連性を分析するためにも，268 種類から重要なものが厳選されていることが望ましい．今回，特徴量選択には貪欲法による探索を用いた.

貪欲法とは，近似解を求めるアルゴリズムである．本研究においては特徴量の組み合わせを探索する目的で用いる. 具体的には，各特徴を 1 つずつ単体で用いたときの推定精度を比較し，最も有効な特徴を確認する．その後，有効と確認した特徴に，その他の各特徴を 1 つずつ加えて学習させた場合の推定精度を比較し，学習に追加するのに最も有効な特徴を確認する．以上を繰り返し適切な特徴量の組み合わせを探る.

3.5 学習アルゴリズム

機械学習アルゴリズムは Support Vector Machine (SVM) [8]を用いた．SVM とは，1995 年に提案されたパターン認識手法であり，（1）大局的最適解が保証される，（2）未観測のパターンに対する識別能力が高い，（3）ハイパパラメータ探索が容易，（4）識別時の計算量が少ない，（5）学習を効率よく行うアルゴリズムが存在する，などの特徴がある. SVM は, バイオインフォマティクス[9]や画像認識[10], テキスト分類[11]などの分野で使われているアルゴリズムだが, 吉川ら[7]や Shenoy ら[12]が筋電位を用いた手の動作識別に利用している．本研究では，Python の機械学習ライブラリである scikit-learn[13]に含まれる SVC を用いた.

4. 評価実験

4.1 身体的負荷推定

提案手法の実現性を評価するためにデータ収集実験を行う．筋肉に段階的な負荷をかけた状態と負荷のない状態の筋電位を計測し，各状態のデータから負荷量を推定する. 被験者は 22 歳～25 歳の健常男性 11 名である．被験者は椅子に座り，右手にダンベルを持ち計測を行う．肘を直角に曲げた状態を維持する keep 状態と，アームカールを行う curl 状態によって，看護業務における体位変換のような腕に対する身体的負荷を再現する．アームカールとは上腕二頭筋を鍛えるトレーニングの一つであり，肘関節を曲げる動作を繰り返す運動である．アームカールは楽に椅子に座った状態で行った．本実験で行ったアームカールのペースは約 1 秒間に 1 回である．与える身体的負荷は，負荷の大きさを小，中，大を想定し，1kg，3kg，5kg の 3 種類のダンベルを用いた．具体的な身体的負荷状態は，（R）リラックス状態,（1_k）1kg_keep,（1_c）1kg_curl,（3_k）3kg_keep,（3_c）3kg_curl,（5_k）5kg_keep,（5_c）5kg_curl の 7 種類とした．各状態の詳細を表 2 に示す.

ⓒ2019 Information Processing Society of Japan

表 2　再現した身体的負荷状態

R	負荷をかけず力を抜いた状態
1_k	1kg のダンベルを持ち，腕を直角に曲げた状態を維持する
1_c	1kg のダンベルを持ち，アームカールを行う
3_k	3kg のダンベルを持ち，腕を直角に曲げた状態を維持する
3_c	3kg のダンベルを持ち，アームカールを行う
5_k	5kg のダンベルを持ち，腕を直角に曲げた状態を維持する
5_c	5kg のダンベルを持ち，アームカールを行う

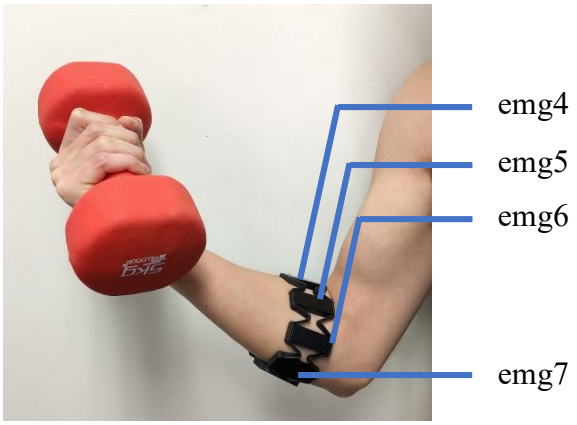

図 2　実験中の筋電位センサの位置

計測時の筋電位センサ位置の一部を図 2 に示す．筋電位センサは図 2 のように腕に巻き付くように搭載されている．本稿では，筋電位センサが図 2 のように，emg4 が概ね肘の内側となるように向きを指定し計測を行った．

ダンベルを持つ腕の前腕部に Myo を装着し，各負荷状態に対し 10 秒間の計測を行う．以上を 1 セッションと定義し 3 セッション分のデータを得る．各セッション間では Myo の着脱を行い，電極の位置がずれていても身体的負荷を推定できるか評価する．得られた筋電位データに対し特徴量を抽出しモデルを学習する．本研究は，個人ごとにキャリブレーションを行わないことを想定しているため，各被験者に依存しない汎用的な特徴を発見することを目的とする．よって本研究では，学習したモデルの評価に被験者ごとにデータを分割した LOSO-CV（Leave-One Subject-Out CV）を用いる．

4.2 負荷推定の結果

貪欲法により学習に用いる特徴量数を増やし、それに伴う Accuracy の変化を図 3 に示す．特徴量数 69 で Accuracy が最大の 82.7%となった．そのときの LOSO-CV の結果を表 3 に示す. 各状態の F 値はリラックス状態が最大の 99.5%となり, 負荷をかけた状態では 1_k が最大の 91.9%となり，最小は 3_c の 65.4%となった．F 値を比較すると，負荷量が大きくなるにつれて推定精度が下がる傾向がみられる．また，全体の誤り傾向に着目すると，近しい負荷状態間で誤認識する傾向があることを確認した．よって，各状態に関し R，1_k，1_c，3_k，3_c，5_k，5_c の順に順序関係があると仮定すると，前後±1 状態への誤りを許容した場合，93.0%の精度で推定できた．以上より，誤り方には規則性があると考え次節で重要因子を考察する．

4.3 重要因子分析

身体的負荷推定に有効な特徴を考察する．貪欲法により身体的負荷推定に有効な特徴を探索する．各状態に対し，貪欲法で選んだ特徴 30 種類の値の分布を比較する．また，貪欲法の過程による Accuracy の変化をもとに，学習に適切な特徴量数を考察する．貪欲法により求めた重要度が高い特徴のうち，推定に有効な上位 30 種類の特徴の値の分布を各負荷状態に対して比較した．各状態で値の分布が異なるとみられた特徴は，時間領域では emg4 の標準偏差（以下 emg4_std とする），周波数領域では emg5 に対し高フーリエ変換（FFT）して求めた低周波数領域内の第一四分位数（以下 emg5_FFT_low_25%とする）であった．

身体的状態に対し，それぞれの特徴の分布を図 4，図 5 の箱ひげ図に示す．図 4，5 より，身体的負荷により emg4_std

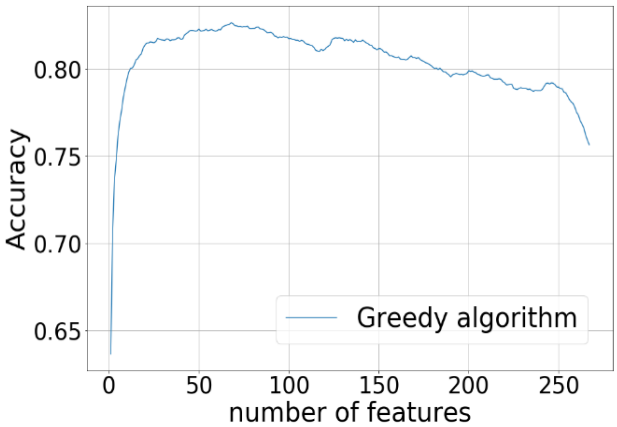

図 3　貪欲法による Accuracy の変化

表 3　貪欲法で求めた特徴 69 個での LOSO-CV の結果

		真の負荷状態						
		R	1_k	1_c	3_k	3_c	5_k	5_c
予測した負荷状態	R	1082	3	0	0	0	0	0
	1_k	6	1026	82	31	0	0	0
	1_c	0	52	884	80	83	1	6
	3_k	0	6	47	907	32	42	0
	3_c	0	2	71	53	723	131	141
	5_k	0	0	1	15	125	806	73
	5_c	0	0	4	3	126	103	865
F 値		99.5	91.9	80.5	85.5	65.4	76.7	79.1
Acc		82.7						

ⓒ2019 Information Processing Society of Japan

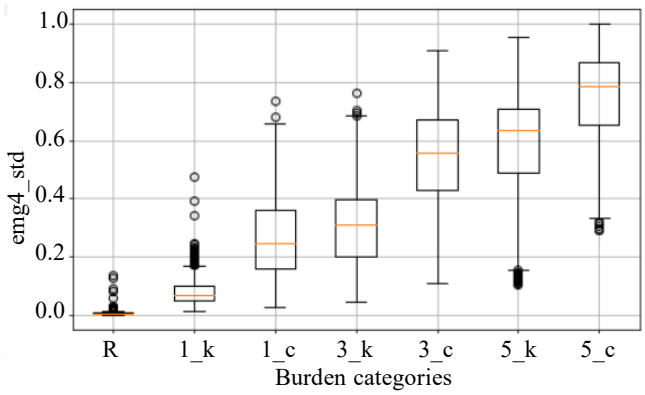

図 4　emg4 の標準偏差の分布

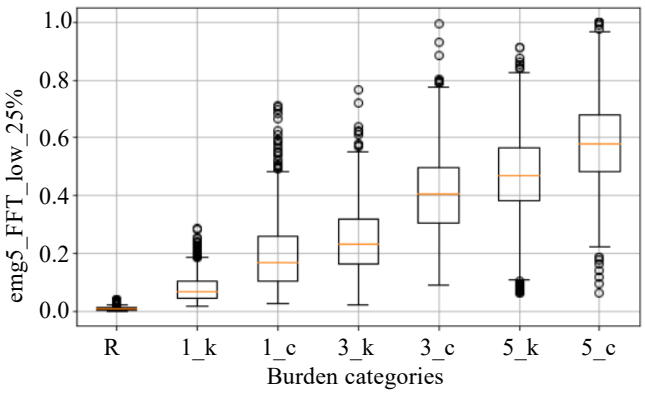

図 5　emg5 の FFT によって求めた低周波領域内における第一四分位数の分布

と emg5_FFT_low_25%は線形に変化する傾向が見られた．ここで状態をリラックスと keep，ならびにリラックスと curl のみで分布を比較した場合，各特徴の四分位範囲に着目すると，各負荷状態において特徴の分布が異なる．

また図 4 より，1_c と 3_k，3_c と 5_k において分布が類似することを確認した．curl 状態に関し，ダンベルが最低位置まで下がった瞬間は，ダンベルの重さに加え，ダンベルに蓄えられた運動エネルギーによる負荷がかかったため分布が上に広がったと考えられる．また，keep 状態に関し，ダンベルを支えている際，無意識のうちに腕を体に預け負荷を逃がしたことにより keep 状態の分布が下に広がったと考えられる．

また，被験者ごとの個人差による各特徴量の分布により，推定精度の低下が生じることが考えられる．被験者ごとの特徴分布を比較し，特徴分布パターンを分析する．特徴分布が分かれていた emg4_std に対し，被験者 11 名を比較し，その中から分布パターンの差異が顕著に現れている被験者 6 名の特徴分布を図 6 に示す．確認できた分布パターンは大きく分けて以下の 3 種類である．

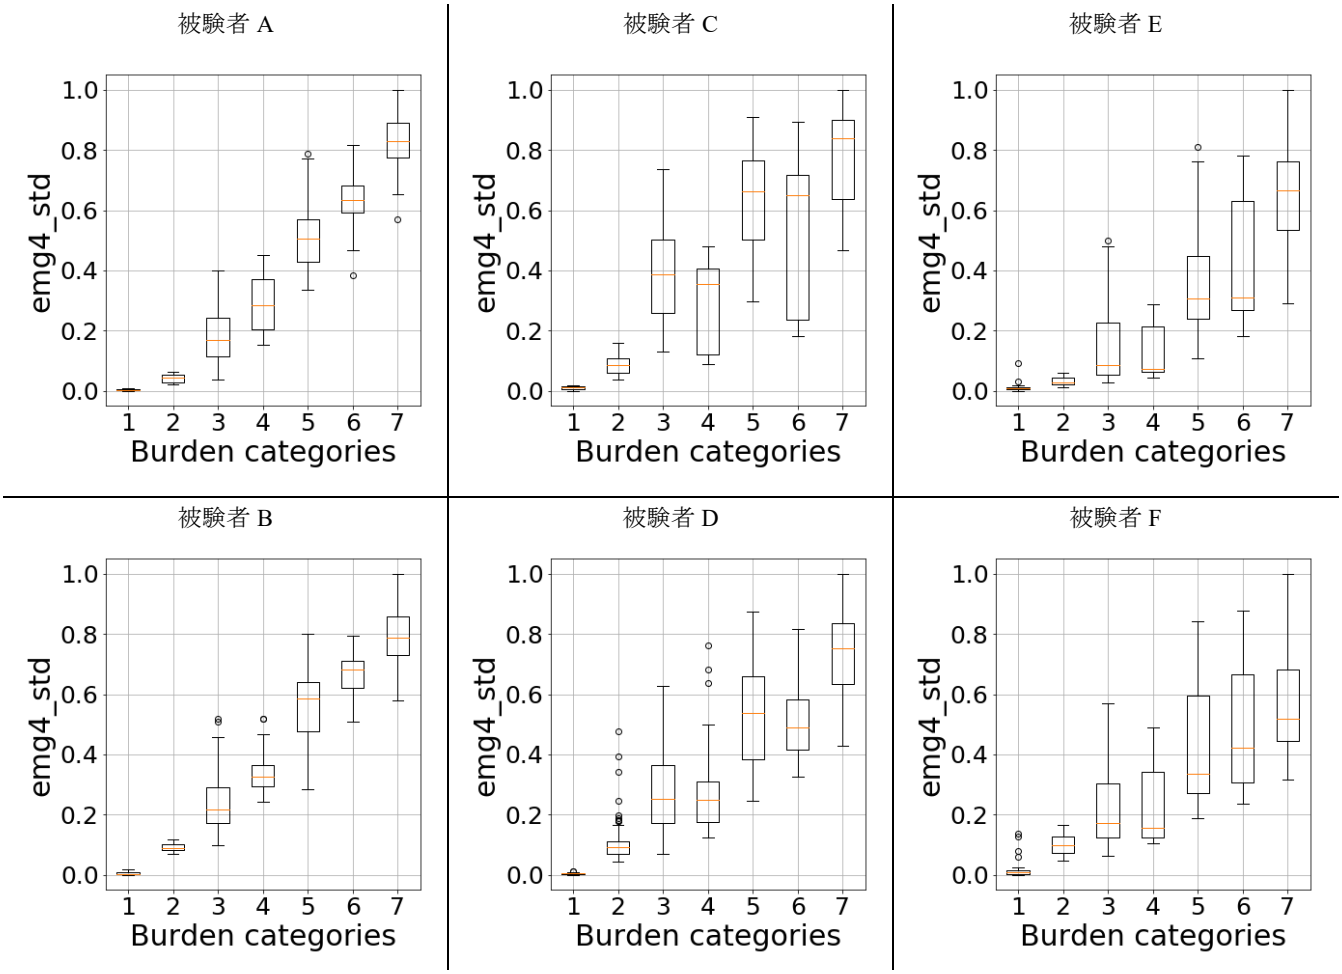

図 6　各被験者の特徴の分布

ⓒ2019 Information Processing Society of Japan

1. 線形変化パターン（被験者 A, B）
2. keep 状態と curl 状態において，それぞれ異なる線形変化パターン（被験者 C, D）
3. 分布が比較的広いパターン（被験者 E, F）

1 は動作の有無にかかわらず，負荷による特徴の値の線形変化の傾きが近い．それに対し，2 は動作の有無により，特徴の線形変化の傾きが異なる．3 は各特徴の値が全体的に低い．このように，同じ負荷をかけていても，分布には個人差が生じた．しかし同一動作に対し，特徴の変化は線形に近いものであった. よって, 本研究で提案する手法は, 本実験では設定しなかった 2kg や 4kg のような中間の負荷や，より大きな負荷に対しても予測できると考えられる．

5. おわりに

本研究では，アームバンド型のウェアラブルデバイスである Myo を用い, 簡易計測できる筋電位データから身体的負荷を定量的に推定する手法を提案し，その基礎検証を行った．本研究により，Myo による筋電位の簡易計測において，最適に特徴量を選択することにより定義した 7 状態を 82.7%の精度で推定できることを示した．推定結果の誤り分布に着目すると，負荷量が近しい状態同士で誤認識する傾向を確認した．

負荷量推定の重要度が高い特徴に着目すると，特に腕橈骨筋付近の筋肉から得られる筋電位が有用であることを確認した．動作によって筋電位の変化傾向は異なる場合においても，同一動作においては線形に変化する傾向があることを確認した．よって加速度センサなどを併用し動作を識別する機能を追加することで，未知の負荷量に対しても推定できると期待される．

本研究により，看護師の負担を定量的に検出し，業務負担を可視化することが期待される．負担の一極集中を避ける判断材料とすることで看護師の負担軽減に貢献することを目指す．

今後は，本稿で探索した重要な特徴量選択に加え，機械学習アルゴリズムのパラメータチューニングを行い，身体的負荷推定精度向上を目指す．そして，現実的な看護業務を想定した検証も行っていく．

謝辞　本研究の一部は科学研究費助成事業若手研究（B）（16K16175）並びに福井大学ライフサイエンスイノベーションセンターの学部官共同研究（TR 研究）H30 助成金によるものである．ここに謝意を表す．

参考文献

[1] 角康之, 伊藤禎宣, 松口哲也, シドニーフェルス, 間瀬健二: 協調的なインタラクションの記録と解釈, 情報処理学会論文誌, Vol. 44, No. 11, pp.2628-2637(2003).
[2] 桑原教彰, 野間春生, 鉄谷信二, 萩田紀博, 小暮潔, 伊関洋: ウェアラブルセンサによる看護業務の自動行動計測手法, 情報処理学会論文誌, Vol.44, No.11, pp. 2638-2648(2003)
[3] Inoue, S. and Ueda, N. and Nohara, Y. and Nakashima, N.: Recognizing and Understanding Nursing Activities for a Whole Day with a Big Dataset, Journal of Information Processing, Vol. 24, No. 6, pp.1–14 (2016).
[4] 渡邊純一郎, 藤田真理奈, 矢野和男, 金坂秀雄, 長谷川智之: コールセンタにおける職場の活発度が生産性に与える影響の定量評価, 情報処理学会論文誌, Vol. 54, No. 4, pp. 1470-1479(2013).
[5] 磯田達也, 井上創造, 花沢昭俊, 野原康伸, 白水麻子, 杉山康彦, 平田真理, 町田京子, 中島直樹: 携帯センサと近接センサを用いた看護業務分析, 情報処理学会論文誌, Vol. 57, No. 10, pp. 2197-2209(2016).
[6] Kogi, K. and Hakamada, T.: Frequency analysis of the surface electromyogram in rnuscle fatigue, J. Sci. Labour(Tokyo), 38, pp. 519-528(1962)
[7] 吉川雅博, 三河正彦, 田中和世: 筋電位を利用したサポートベクターマシンによる手のリアルタイム動作識別, 電子情報通信学会論文誌 D, Vol.J92-D, No. 1, pp. 93-103(2009).
[8] Cortes, C. and Vapnik, V.: Support-vector networks, Machine Learning, Vol. 20, pp. 273-297(1995).
[9] Hirose, S. and Shimizu, K. and Kanai, S. and Kuroda, Y. and Noguchi, T.: POODLE-L: A two-level SVM prediction system for reliably predicting long disordered regions, Bioinformatics, Vol. 23, No. 17, pp. 2046–2053(2007).
[10] Pontil, M. and Verri, A.: Support vector machines for 3d object recognition, IEEE Trans. Pattern Anal. Mach. Intell., Vol. 20, No. 6, pp. 637–646(1998).
[11] Lodhi, H. and Saunders, C. and Shawe-Taylor, J. and Cristianini, N. and Watkins, C.: Text classification using string kernels, J. Machine Learning Res., Vol. 2, pp. 419–444(2002).
[12] Shenoy, P. and Miller, K.J. and Crawford, B. and Rao, R.P.N.: Online electromyographic control of a robotic prosthesis, IEEE Trans. Biomed. Eng., vol.55, No.3, pp.1128–1135(2008).
[13] scikit-learn: machine learning in python- scikit-learn 0.20.2 documentation.

ⓒ2019 Information Processing Society of Japan