

ヒューマン・マシン・システム研究部会セッション

ヒューマンファクタに係る新たな展開

New development in human factors

(3) 行動センシングとAIによるヒューマンエラー対策

(3) Preventing human error by behavior sensing and artificial intelligence

*梶原 祐輔¹, 植村 喜弘¹, 島川 博光¹¹立命館大学

1. 緒言




図1 IoTとAIを利用した認知負荷推定

我々は電車の吊り棚にかばんを置いたまま、置き忘れて電車を降りる（ラプス）、履歴書を書いているときにうっかり書く欄を間違える（スリップ）、ソフトウェアマニュアルに記載している手順を『必要ない手順だ』と自己判断し、飛ばし、PCをフリーズさせた（ミスレイク・違反）などのヒューマンエラーを度々、起こしながら、日常生活を営んでいる。これらのヒューマンエラーは日常生活では問題にならないことが多いが、産業では多大な被害を産む悲惨な事故につながることもある。それゆえ、ヒューマンエラーは未然に防がれる必要がある。

我々が保有する記憶や認知を処理する資源（ワーキングメモリ）[1]や注意資源[2]は有限であるが、認知や注意を向ける対象はそれに比べて多い。それゆえ、我々は自己が保有しているワーキングメモリや注意資源を超える、認知負荷の高いタスクが最優先課題として与えられたとき、このタスクに十分なワーキングメモリや注意資源を割り当てるために、無意識・意識的に優先度の低いタスクの自動的処理を行う。タスクの自動的処理は統制的処理と比較し、注意資源やワーキングメモリを消費しない。このさいに自動化すべきでない、設備・計器の確認や事業計画の確認などのタスクが自動化された場合、設備の不備や異常事態の見落としなどのヒューマンエラーが発生する可能性が高くなる。

認知負荷はアンケートで測定できるが、それを随時測定するのは作業者の負担になり、それ自体が認知負荷となる可能性がある。また随時変化する認知負荷は測定できない。それゆえ、本研究ではIoT技術を利用し、取得した行動の情報をAIに学習させ、自動的に認知負荷を推定する。

本論文ではIoT技術と人工知能を活用した認知負荷推定手法[3]を解説する。IoT技術で収集したセンサーデータから特徴を抽出し、機械学習により推論することでビッグデータを認知負荷などの知識に変換できる（図1）。システムが出力した知識は、ヒューマンエラー対策に活用できる。

2. ヒューマンエラーと認知負荷

作業者は知覚、現状把握、未来予測を経て、動的に意思決定[4]し、行動を実施する（図2）。各フェーズの状態には注意が向けられている。ワーキングメモリは眠気[5]で増減する注意資源を配分している。ワーキングメモリも有限な資源であり、注意制御や処理資源の確保などを行う中央実行系と視覚・空間情報の短期貯蔵庫である視空間スケッチパッド、言語の短期貯蔵庫である音韻ループ、長期記憶から引き出した記憶の短期貯蔵庫であるエピソードバッファで構成されている。またワーキングメモリは注意資源の配分の他に、タスクの自動的処理が適切に行えるよう、対象への注意の持続や習慣的反応の抑制、競合の解消などを行っている。高い認知負荷がかかり、ワーキングメモリが枯渇すると、注意配分や意思決定・行動の自動化を誤り、ヒューマンエラーを引き起こす。

ヒューマンエラー防止には現場力の向上が必要不可欠である[6]。現場力は、監視能力、予見能力、対処能力、学習能力から成る。状況の変化を監視し、状況の変化から次の状況の変化を予見し、対処能力で予測した状況の変化に対処し、次の状況の変化に備えて学習する。しかし、監視、予見、対処、学習には多くの注意資源やワーキングメモリを要する。作業者のワーキングメモリや注意資源は有限であり、これらをすべて完璧に実施することは難しい。




図2 ワーキングメモリ・注意資源と動的意思決定の関係

3. 行動センシングとAIによる認知負荷の推定

3-1. IoT技術とAIによる現場力の向上

作業者と人工知能を協同させ、現場力を向上させる。従来は作業者が監視、予見、対処、学習をすべて行っていたが、作業者のワーキングメモリや注意資源は有限であり、これらをすべて完璧に実施することは難しい。それゆえ、このプロセスの一部を人工知能に委託することを考える。IoT技術で作業者の動作や心身の状態を定量的に取得し、それらを人工知能に学習させ、作業者の認知負荷を推定する。作業者はIoT技術と人工知能による監視結果と予見結果を受け、ヒューマンエラーを未然に防ぐ策を実施する。作業者はヒューマンエラー対策や作業に十分な注意や認知を向けることができ、ヒューマンエラーの発生率の低下が期待できる。また人工知能は作業者と異なり、監視・予見するアルゴリズムが明らかであり、監視・予見に成功する確率を見積もることができる。さらに人工知能はサーバ上で実装できる。初期費用はかかるが、長期の運用を考えた場合、人件費と比較して少ない。

3-2. IoT技術による作業者の動作の監視

認知負荷の推定では空間分解能で優れる加速度センサを腰に装着し、作業者の動作を取得する。センサは熱や音、画像などの外界の情報を数値に変換する電子機器である。センサはKinectやカメラ、レーザレンジファインダなどの非接触で情報を取得する非接触型センサと加速度センサ、脈拍センサなどの測定対象者に接触させて情報を取得する接触型センサがある。非接触型センサは広範囲を測定可能で、電源に接続することで長時間持続して、使用できる。接触型センサは測定できる範囲は狭いが、測定対象者に装着

して測定するため、空間分解能が高い。しかし、接触型センサの多くはバッテリーや電池で稼働するため、駆動時間は短い。接触型センサと非接触型センサはそれぞれ利点・欠点があり、用途に合わせてセンサを選択する必要がある。

3-3. 行動の自動化を表す特徴の抽出

作業者は保有する注意資源やワーキングメモリを超える認知負荷がかかると、優先度の高いタスクにワーキングメモリや注意資源を割り当てるために、優先度の低いタスクをスキーマにしたがい、自動的処理する。我々は自動的処理されるタスクとして歩行に着目した。歩行は優先度の低い行動でかつ、大半の作業でスキーマが構築されている行動である。自動的処理された歩行はその作業者にとって習慣的でかつ負荷が少ない周期で実現される。これは統制された歩行とは異なる周期で身体が動くことを意味する。

我々はこの特徴を加速度と角速度のパワースペクトルで表現する。作業者に対し垂直方向を x 軸、水平方向を y 軸、進行方向を z 軸と定義する。加速度を $a=[a_x, a_y, a_z]^T$ 、角速度を $v=[v_x, v_y, v_z]^T$ と定義する。それぞれの成分は x , y , z 軸方向の加速度及び角速度を示している。 a と v に対し、フーリエ変換を行い、各周波数におけるパワースペクトル値を求める。パワースペクトルは各周波数帯の振れ幅を示している。自動化された歩行と統制された歩行の周期が異なる場合、それぞれの特定周波数帯のパワースペクトル値が高くなる。これに加え、加速度センサの設置角度による各軸の測定誤差を考慮するために、 a と v のユークリッドノルムを求める。さらに体のぶれにより、取得される加速度や角速度は急激に変化する。この変化を取得するために、本研究ではピーク・バレー分析を適用する。加速度・角速度の変動が閾値よりも大きい場合、それをピーク・バレーとして検出する。閾値は a と v の最大値と最小値の差分の 25%, 50%, 75%, 100% に設定した。ピーク・バレーの平均値及び標準偏差、そして検出された数を特徴成分とした。

3-4. AI による認知負荷の推定

行動の自動化を表す特徴を、AI に学習させ、認知負荷を推定する。本研究では AI に Random Forest (RF) を用いる。RF は、学習データに基づいて複数の決定木を構成する。本研究では CART アルゴリズムで決定木を構築した。CART アルゴリズムは、親ノードと子ノードのジニ係数の差が最大となる説明変数を選択する。このジニ係数の差は選択された説明変数の推定に貢献した割合を表している。それゆえ、各説明変数でジニ係数の差を総和することで、各説明変数の重要度（変数重要度）が求められる。未知のデータが入力された場合、複数の決定木が出力した結果を平均化し、認知負荷を推定する。

4. 認知負荷の推定精度を検証

4-1. 実験内容

3 章で示した認知負荷推定手法の精度を検証するための実験を行った。加速度と角速度のサンプリング周波数は 100Hz である。一般的な歩行速度は約 4.0 km/h、歩幅は約 60~90 cm である。歩行速度を歩幅で除算すると、1 歩あたり約 0.55~0.8 秒である。本研究では加速度センサを腰に装着したことから、加速度には右足と左足の動きによって変化する。加速度は 1 歩の間で足を上げるときと足を下ろすときにそれぞれ変化する。それゆえ、1 歩を表す加速度の周波数は 2.5Hz~3.6Hz である。本実験で用いたセンサのナイキスト周波数は 50Hz である。したがって、本手法で用いたセンサは歩行の特徴を算出する上で十分な分解能を有する。被験者は 20 代の男性 14 名、女性 6 名である。それぞれの被験者は加速度センサを尾骶骨上部 5.0cm 地点に装着した。装着された加速度センサはノートパソコンに bluetooth を用いて接続されている。被験者は実験開始位置から 14 m 直進する。また歩行開始時に、4.2 節で示すサブタスクを負荷する。被験者は歩行が終了するまでサブタスクに回答し続ける。本研究ではこの回答数を基に認知負荷を定義する。この認知負荷をかけた状態での歩行を 20 回、認知負荷をかけなかった状態での歩行を 20 回行った。また被験者の肉体的疲労の影響を考慮し、10 回歩行するごとに 5 分間の休憩を挟んだ。

4-2. 認知負荷

我々は被験者に認知負荷をかけるために、被験者にサブタスクを負荷した。サブタスクは想起問題である。実験実施者は被験者にある 1 つのトピックを歩行開始時に伝える。被験者は、それに当てはまるものを口頭で実験実施者に可能な限り多く伝える。被験者は、実験実施者から与えられた「白い花」という言

葉を何度か頭の中で繰り返す、このさい、音韻ループが使用される。同時に「白い花」のイメージを頭の中に思い描くため、視覚スケッチパッドが使用される。また、自身が言った単語を覚えておくために、エピソードバッファが使用される。これらに注意や資源を割り当てる必要があるため、中央処理系も圧迫される。したがって、この想起問題を被験者に与えることでワーキングメモリの資源を枯渇させることができる。

本研究では、トピックに当てはまる回答数が少ないほど認知負荷が高いと定義する。サブタスクの応答数は、個人差を考慮して0から1に正規化される。正規化された応答数は目的変数としてRFに学習される。推定精度を検証するために、1人の被験者をテストデータ、それ以外を学習データとする20-fold-cross-validationを実施した。RFにテストデータを入力したさいの推定誤差の平均で本手法の推定精度を評価する。推定誤差は正規化された応答とRFの出力結果の差のL1ノルムとした。

4-3. 実験結果




図3 各課題における推定誤差

推定誤差の平均±標準偏差は 0.20 ± 0.04 だった (図3)。この結果は本手法で少なくとも高い認知負荷がかかっている状態 (高認知負荷)、中程度の認知負荷がかかっている状態 (中認知負荷)、低い認知負荷がかかっている状態 (低認知負荷) を推定できることを示唆している。正規化した応答数が0以上0.334未満の場合を高認知負荷、0.334以上0.667未満を中認知負荷、0.667以上1以下を低認知負荷として、各状態の加速度と角速度のユークリッドノルムを求めた (表1)。表1の加速度は主に歩行速度、角速度は主に身体のぶれを表している。表1から高認知負荷時に歩行した場合、低認知負荷時の歩行に比べ、歩行速度が遅いことが示唆された。低認知負荷時の歩行は高認知負荷時の歩行と同等の身体のぶれが表れた。しかし、低認知負荷時の歩行速度が高認知負荷時の歩行速度に比べ、遅いことから低認知負荷時の身体のぶれは統制された歩行に由来していることが示唆された。中認知負荷時の歩行は高認知負荷時の歩行より若干遅い歩行速度で、身体のぶれが低認知負荷時の歩行と比べ、小さかった。次に推定する上で重要なファクターをRFが出力した変数重要度から考察する。各周波数の変数重要度を正規化した結果を図4に示す。変数重要度が高い周波数帯域を赤色で示した。図4から1.5Hz～2.5Hz、3.5Hz～3.6Hzの周波数帯域のパワースペクトル値が認知負荷を推定する上で重要だった。1.5Hz～2.5Hzは一般的な歩行時に表れる加速度の周波数帯域の下限以下の周波数帯域である。3.5Hz～3.6Hzは一般的な歩行時に表れる加速度の周波数帯域の上限付近の周波数帯域である。

低認知負荷時は歩行を意識的に統制できるため、歩行速度が速く、歩行以外に由来する身体のぶれも少

ない。中認知負荷時は優先度の高いサブタスクに回答するために、歩行を自動化し、歩行を統制するために割り当てていたワーキングメモリの資源を解放する。このさいに歩行の自動化が適切に実施されたため、歩行速度が遅くなり、身体の不れも小さくなった。高認知負荷時は中認知負荷時と同様に優先度の高いサブタスクに回答するために、歩行を自動化し、歩行を統制するために割り当てていたワーキングメモリの資源を解放する。しかし、高認知負荷時はワーキングメモリの容量を超えるサブタスクが与えられたため、自動化を統制する領域にまで影響を及ぼし、歩行の自動化を失敗している。その結果、自動化された歩行にたびたび統制された歩行が表れ、その切り替えによって身体の不れが大きくなったことが示唆された。この特徴を表す周波数帯域は一般的な歩行時に表れる加速度の周波数帯域の下限以下の周波数帯域と上限付近の周波数帯域のパワースペクトルである。これらの周波数帯域のパワースペクトル値を活用することで 0.20 ± 0.04 の誤差で認知負荷を推定できる。

表 1 各認知負荷における加速度と角速度のユークリッドノルム

	高	中	低
加速度	609.54	538.14	1117
角速度	1076.7	762.49	1213.1




図 4 変数重要度が高い周波数帯域

5. 結論

本論文では認知負荷をかけたさいの行動の自動化に着目した認知負荷推定手法を解説した。本手法はベルトに加速度センサを付けることで、認知負荷を 0.20 ± 0.04 の誤差で推定でき、実用性が高い。今後はスキルが必要な複雑な作業や確認作業に対して、本手法を適用し、有用性を示す。

参考文献

- [1] A. Baddeley, "The episodic buffer: a new component of working memory?." Trends in cognitive sciences, 4(11), pp. 417-423 (2000).
- [2] D. Kahneman, "Attention and effort." Englewood Cliffs, NJ: Prentice-Hall, Vol. 1063(1973).
- [3] Uemura, Y., Kajiwar, Y., & Shimakawa, H. (2017). Figuring out Distraction Degree from Working Memory Consumption for Pedestrian Safety. International Journal of Internet of Things, 6(1), 1-8.
- [4] M. R. Endsley, "Toward a Theory of Situation Awareness in Dynamic Systems." Human Factors, 37(1), pp.32-64(1995).
- [5] E. Hoddes, V. Zarcone, H. Smythe, R. Phillips, W. C. Dement, "Quantification of sleepiness: a new approach." Psychophysiology, 10(4), pp.431-436 (1973).
- [6] E. Hollnagel, D. D. Woods, & N. Leveson, "Resilience engineering: Concepts and precepts." Ashgate Publishing, Ltd. (2007).

*Yusuke Kajiwar¹, Yoshinobu Uemura¹ and Hiromitsu Shimakawa¹

¹Ritsumeikan Univ.