

遺伝的進化学習による離床センサの自動キャリブレーション

Automatic Calibration of Bed-Leaving Sensors Based on Genetic Evolutionary Learning

○平松大樹, 間所洋和, 佐藤和人, 下井信浩

○ Daiju Hiramatsu, Hirokazu Madokoro, Kazuhito Sato, and Nobuhiro Shimoi

秋田県立大学大学院 システム科学技術研究科

Graduate School of Systems Science and Technology, Akita Prefectural University

キーワード : GNP (Genetic Network Programming), CPN(Counter Propagation Network), 離床センサ (Bed-Leaving Sensors), 離床判定 (Bed-Leaving Detection), 自動キャリブレーション (Automatic Calibration)

連絡先 : 〒 015-0055 秋田県由利本荘市土谷字海老ノ口 84-4

秋田県立大学 システム科学技術研究科 機械知能システム学専攻 脳情報工学研究室

平松大樹, TEL:0184-27-2081, FAX:0184-27-2180, E-mail: M19A019@akita-pu.ac.jp

1. 緒言

現在, 日本では人口が減少していく中で, 高齢化率は上昇している. 平成 27 年の国勢調査では, 65 歳以上の人口が総人口に占める割合は 26.6 % となっており, 調査開始以来最高となっている. 対して, 15 歳未満の人口が占める割合は 12.6 % となっており, 調査開始以来最低である¹⁾. また, 内閣府の資料によると, 65 歳以上の高齢者の中で半数近くは, 日常生活の中で健康に影響のある何らかの自覚症状を訴えていることが報告されている²⁾. このことをふまえると, 今後は介護や支援を必要とする高齢者が増加する一方で, それを支える労働者人口は減少が見込まれる. このため介護現場では, 現状においても深刻である介護職員の人手不足が, 一層深刻化する懸念がある. 少数のスタッフで大勢の入居者を介護することになるため, 就寝中の管理が手薄になることも問題となっている³⁾. その中でも特に, 高齢者の転倒・転落事故は発生頻度が高いため, この対策として, 離床センサを用いた予防策を施す施設が増加している.

間所らの先行研究では, ベッド上に敷設された複数

のパッド形状の荷重センサにより姿勢を判定する手法が提案されている⁶⁾. しかしながら, 判定に用いられている対向伝播ネットワーク (Counter Propagation Network:CPN) は, 体重や体格などの個人差による特徴の違いを十分に吸収できない. そのため, 被験者によっては判定精度が極端に低下する場合もある. また, センサによって得られたデータは, 自己組織化マップ (Self-Organizing Maps:SOM) によりノイズを取り除いているものの, 体重や体格などの個人差に対してキャリブレーションは施されていない. この問題を解決するために本研究では, 進化学習に基づく遺伝的ネットワークプログラミング (Genetic Network Programming:GNP) を用いて, センサ波形を補正もしくは整形するためのフィルタセットを作成し, 被験者に応じた自動キャリブレーションの確立を目的とする.

2. 提案手法

2.1 遺伝的ネットワークプログラミング

GNP は、ノードをネットワーク上に接続することによって、プログラムの自動生成を行う手法である。これにより、Koza によって提案された生命の進化から影響を受けた進化学習の手法であり、遺伝プログラム生成や学習、推論、概念形成などに応用することを目的としている遺伝的プログラミング (Genetic Programming:GP) と比較して、ブロード等の発生しない解空間の効率的な探索が可能になる⁴⁾⁵⁾。GNP は、分岐ノード、処理ノードの 2 種類のノードからなり、ノード及びノード間に遅れ時間を設定している。分岐ノードは GP の非終端記号に、処理ノードは、終端記号に対応している。

GP と GNP との相違は、遺伝子の構造にある⁵⁾。進化の方式は、GP はツリー構造の遺伝子を持つため突然変異や交叉によってツリーの深さが無限に成長する可能性がある。これは、解の探索空間を広め、その中で真の最適解を探索するという点では優れているが、ツリーのブロードにより探索空間が不必要に拡大すると探索効率が減少する点では欠点となる。また、GP ではツリー構造ゆえに、ルートノードに近いノードに突然変異や交叉が生じると、その適合度に対する影響は他の終端ノードに近いノードより大きくなる。つまり、GP では、ノード毎の突然変異率や交叉率が同じでもノードの変異による適合度への影響度合いはノード毎に異なる構造となっている。したがって、初期の進化段階において、ルートノードに近いノードが適切に選択されてないと、好ましくない解に初期収束する等の問題が発生する。一方 GNP では、ネットワーク構造の遺伝子を持つ。ネットワーク遺伝子内のノード数は進化過程において不変であり、また、ノードの変更による適合度への影響の度合いはノードによって極端な差が生じない構造となる。

2.2 フィルタセット

センサデータの原波形を補正もしくは整形するためのフィルタセットとして分岐ノードを 6 種類使用している。各分岐ノードはそれぞれ 3 条件を持ち、事前に設定された条件に従って分岐する。これらの

分岐は、GNP が最適な分岐の組み合わせを探索し、グラフネットワークを形成する。

続いて、処理ノードとなるフィルタセットを次に示す。

$$s^{new}(t) = 0.5 \times s^{old}(t) \quad (1)$$

$$s^{new}(t) = 0.8 \times s^{old}(t) \quad (2)$$

$$s^{new}(t) = 0.9 \times s^{old}(t) \quad (3)$$

$$s^{new}(t) = 1.1 \times s^{old}(t) \quad (4)$$

$$s^{new}(t) = 1.2 \times s^{old}(t) \quad (5)$$

$$s^{new}(t) = 1.5 \times s^{old}(t) \quad (6)$$

$$s^{new}(t) = \frac{1}{2} (s^{old}(t-1) + s^{old}(t)) \quad (7)$$

$$s^{new}(t) = \frac{1}{2} (s^{old}(t) + s^{old}(t+1)) \quad (8)$$

$$s^{new}(t) = \frac{1}{3} (s^{old}(t-1) + s^{old}(t) + s^{old}(t+1)) \quad (9)$$

$$s^{new}(t) = 0.25 \times s^{old}(t-1) + 0.5 \times s^{old}(t) + 0.25 \times s^{old}(t+1) \quad (10)$$

$$s^{new}(t) = 0.10 \times s^{old}(t-1) + 0.80 \times s^{old}(t) + 0.10 \times s^{old}(t+1) \quad (11)$$

$$s^{new}(t) = s^{old}(t) + \frac{1}{3} (s^{old}(t-1) + s^{old}(t) + s^{old}(t+1)) \quad (12)$$

$$s^{new}(t) = s^{old}(t) + 0.25 \times s^{old}(t-1) + 0.5 \times s^{old}(t) + 0.25 \times s^{old}(t+1) \quad (13)$$

$$s^{new}(t) = s^{old}(t) + 0.10 \times s^{old}(t-1) + 0.80 \times s^{old}(t) + 0.10 \times s^{old}(t+1) \quad (14)$$

$$s^{new}(t) = s^{old}(t) \quad (15)$$

各処理ノードにおいて，処理の実行後は，呼び出し元のノードに戻らずに，別の処理ノードもしくは分岐ノードに遷移する．これが，GP との基本的な違いの一つである．

3. 評価実験

我々の研究プロジェクトでは，ベッド上に複数のパッド形状の荷重センサを配置し，荷重パターンの分布から，機械学習法により離床判定を行うシステムを提案している⁶⁾．最新のセンサシステムでは，ベッド上に5個の荷重センサを配置して離床判定を行っている．センサデータを取得する際に，被験者には，仰臥位，右側臥位，左側臥位，長座位，短座位，端座位，離床の7姿勢を1パターンとして，20秒ごとに切り替えてもらい，荷重センサによって離床判定に用いるためのベンチマークデータを構築している．また，今回は先行研究によって得られたセンサデータを使用している⁶⁾．先行研究によって，被験者から得られたセンサデータの原波形を図1，図2に示す．また，各データセットの判定精度を表1に示す．

3.1 対象とするセンサデータ

Table 1 各センサデータの判定精度

センサデータ	判定精度 (%)
01	43.28
02	43.39
03	41.23
04	39.64
05	40.81
06	40.35

本研究における自動キャリブレーションの有効性を示すために，先行研究の被験者の中から，判定率が

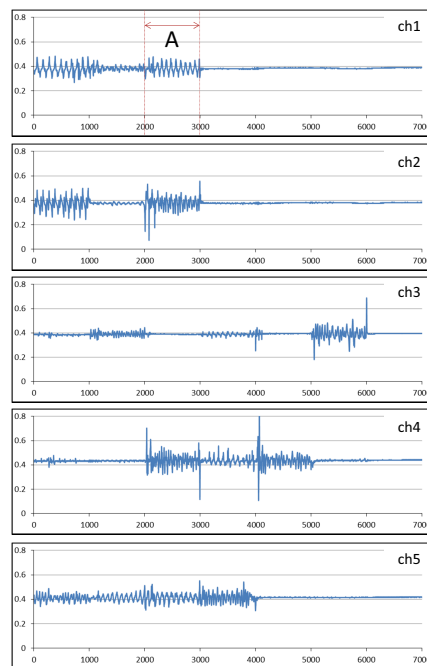


Fig. 1 センサデータ 01 の出力波形

相対的に低い結果となっていた被験者1名を対象とした⁶⁾．センサからの出力を取得する，基板のサンプリングレートは50Hzに設定されており，140秒間計測を行ったため，1パターンにつき7000個のデータ数が得られた．図の縦軸はセンサの出力電圧であり，横軸は経過時間に沿って得られたデータ数である．それぞれの波形において，6000番目から7000番目のデータは，被験者がベッドから離床しているため，センサへの荷重が印加されておらず，波形変化のないことが確認できる．したがって，本実験では，6000番目から7000番目のデータは処理対象外とした．

3.2 実験1

本実験では，判定精度の低い原波形を，判定精度の高い理想波形に近似するように補正もしくは整形することを目的として，GNPによる最適化を試みた．この最適化は，進化的画像処理と同様の考え方に基いている．判定精度の高い理想波形に近似できれば，原波形の判定精度を改善することができる．

本実験で使用したセンサデータは，先行研究の評価実験において使用されていたベンチマークデータ

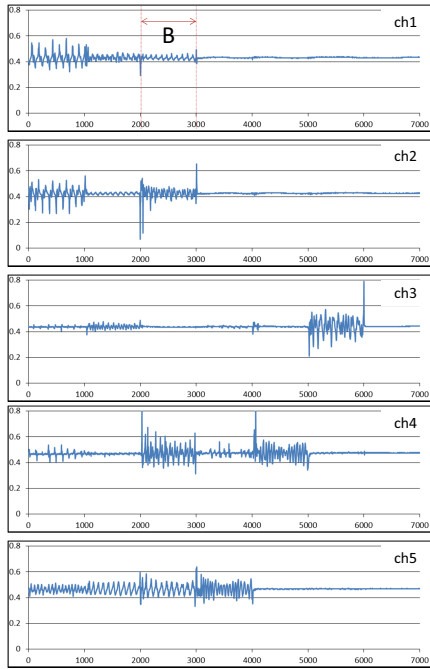


Fig. 2 センサデータ 06 の出力波形

セットのうち、判定精度が最良となったセンサデータを理想波形と設定し、判定精度の最も低かったセンサデータを最適化対象の原波形と設定した⁶⁾。なお、両センサデータとも、チャンネル1の出力のみを使用している。

判定精度となる適合度は、判定精度の低い原波形を補正もしくは整形して判定精度の高い理想波形にどれだけ近似できたかを数値化した。適合度が小さいほど理想波形に近似したことになる。判定精度の低い原波形が判定精度の高い理想波形と類似していくことによって、最終的に離床の判定率が向上するという前提のもとでの予備実験となる。

3.3 設定パラメータ

本実験において、設定しているパラメータを表2に示す。本パラメータは、関連研究などを参考にし、経験的に設定した。なお、パラメータの最適化に関しては、重要な研究課題のひとつであるが、現時点では実施していない。

Table 2 実験1におけるGNPの各パラメータ

パラメータ	数値
判定ノード数	5
処理ノード数	15
世代数	300
交叉による個体数	100
突然変異による個体数	60
エリート個体数	1
交叉確率	0.5
突然変異確率	0.05




Fig. 3 補正もしくは成形後の波形

3.4 実験結果と考察

GNPにより生成されたフィルタセットを施した波形を図3、図4に示す。また、GNPで生成された結果を図5に、最適化後の適合度を表3に示す。

実験結果について考察すると、150世代目の結果は、最終世代となる300世代目の適合度より13.56%高くなっている。したがって、世代数は150世代より多く設定するほうが良いと考えられるが、170世代目以降になると、250世代付近で変化幅が大きくなっているが、最終的な適合度は、大局的に変化していない。そのため、170世代前後で最適解に達したと考えられる。しかしながら、この時の適合度




Fig. 4 世代変化による適合度の変化

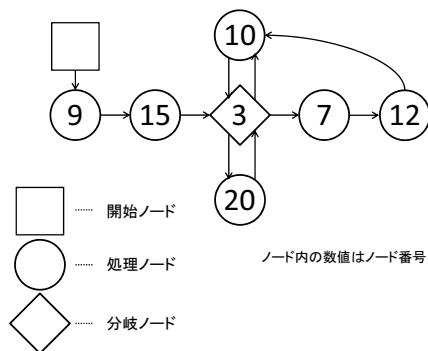


Fig. 5 GNP で生成されたグラフ

Table 3 実験 1 の実験結果

パラメータ	数値
最初の適合度	119.40
最終的な適合度	105.03

は、十分に収束していない。これは、判定精度の高い理想波形と判定精度の低い原波形の間で、特徴差の開きが大きいためと考えられる。例えば、図 1 の範囲 A では、波形が上下に変動しているのに対し、図 2 の範囲 B では、同じ位置で波形は上下しているものの、範囲 A の波形ほど大きくはない。このような異なる特徴があるため、適合度が収束しなかったと考えられる。

3.5 実験 2

本実験では、CPN が出力する判定率を適合度として、最適化の指標に用いた。先行研究では、センサデータを直接 CPN に入力して判定率として精度を評価していたが、本実験では、GNP を用いた進化学習を組み込むことによる、システム全体の精度改善を目的とする⁶⁾。先行研究において収集されたセンサデータの中で、判別率が相対的に低いデータセットをテストデータとして、交差検定により評価しているが、この中に進化学習を組み入れた構成となる。本実験では、判定精度の低い原波形であっても、離床判定に有用な特徴パターンを保持しつつ、判定精度に負の影響を与えていた特徴パターンを補正もしくは整形することができると考えられる。なお、本実験にあたって、6 種類の全てのデータセットを評




Fig. 6 センサデータ 04 の世代変化による適合度の変化

価するのではなく、判定精度が相対的に低かった 4 番目、5 番目、6 番目のデータセットを進化学習の対象とした。

3.6 設定パラメータ

本実験において、設定しているパラメータを表 4 に示す。本パラメータは、関連研究などを参考にし、経験的に設定した。なお、パラメータの最適化に関しては、重要な研究課題のひとつであるが、現時点では実施していない。

Table 4 実験 2 における GNP の各パラメータ

パラメータ	数値
判定ノード数	5
処理ノード数	15
世代数	100
交叉による個体数	200
突然変異による個体数	10
エリート個体数	1
交叉確率	0.5
突然変異確率	0.05

3.7 実験結果と考察

GNP により生成されたフィルタセットを施したデータセットの適合度変化を図 6、図 8、図 10 に示す。また、GNP で生成された実験結果を図 7、図 9、図 11 に、それぞれの精度改善率を表 5、表 6、表 7 に示す。

提案手法による最適化の結果から判定精度は、順に 10.79 %、4.69 %、7.24 %、平均で 7.61 % 改善し

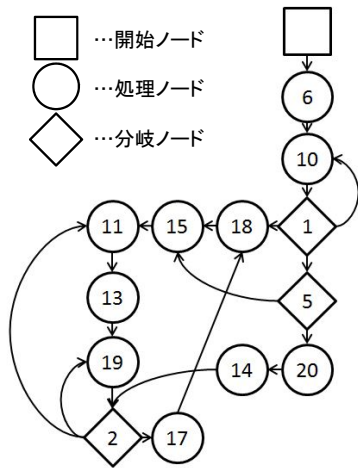


Fig. 7 センサデータ 04 における GNP で生成されたグラフ

Table 5 センサデータ 04 における実験結果

パラメータ	精度 (%)
元波形の適合度	39.64
最終的な適合度	50.43
改善率	10.79

た。適合度の世代による推移では、センサデータ 04, 06 に関しては、初期世代から進化学習前の原波形による元の判定率を上回る適合度が得られ、一定の値に適合度が収束した。センサデータ 05 に関しては、10 世代目前後から元の判定率よりも低い値を示し、その後、適合度の改善がみられるが大きな精度改善は見られなかった。しかし、58 世代目では 4.79 % の精度改善が見られたので、58 世代目を実験結果として採用した。




Fig. 8 センサデータ 05 の世代変化による適合度の変化




Fig. 9 センサデータ 05 における GNP で生成されたグラフ

Table 6 センサデータ 05 における実験結果

パラメータ	精度 (%)
元波形の適合度	40.81
最終的な適合度	45.50
改善率	4.69

4. 結論

本研究では、離床判定における個人差を吸収し、判定精度の向上を目的とし、進化学習の GNP を用いてセンサデータから得られた波形を補正、もしくは整形する手法を提案した。提案手法の基礎的特性ならびに実センサデータに対する有用性を示すために、2 種類の評価実験を実施した。実験 1 では、進化的画像処理の考え方に基づいて、判定精度の低い原波形を、判定精度の高い理想波形に近似させるように GNP で進化学習を行った。その結果、理想波形に近似するように適合度が更新された。続く実験 2 では、判定器となる CPN から得られる判定率を適合度として、学習対象とするセンサデータの自動キャリブレーションにより、判定精度を向上させること




Fig. 10 センサデータ 06 の世代変化による適合度の変化




Fig. 11 センサデータ 06 における GNP で生成されたグラフ

Table 7 センサデータ 06 における実験結果

パラメータ	精度 (%)
元波形の適合度	40.35
最終的な適合度	47.59
改善率	7.24

を目的とした評価実験を実施した。その結果、従来手法において判定率が相対的に低かった 3 パターンのデータセットに対して、精度が順に 10.79 %, 4.79 %, 7.24 %, 平均で 7.61 % 改善する結果が得られた。

今後の課題としては、以下の 3 点が挙げられる。本実験では、単一の被験者による評価実験に留まっていたため、被験者数を増やすことにより、提案手法の一般性を示す必要がある。また、フィルタセットは分岐ノードが 5 セット、処理ノードが 15 セットであったため、両ノードを追加することで、個人差による特徴の違いを吸収し、判定率の更なる向上に結び付けることができる進化学習に向けて、実装と評価を進めたい。そして、GNP の動作を支配するパラメータは現状、先行研究等を参考にして経験的に設定したが、本研究で対象としているデータセットに対して、最適パラメータとは言えない⁶⁾。したがって、各パラメータにおける特性や感度の変化を、判定率の視点から評価するとともに、最適化を行う必要がある。

参考文献

- 1) 平成 27 年度国勢調査人口等基本集計 結果の概要。
- 2) 平成 28 年版高齢社会白書 (概要版) 内閣府。
- 3) 内匠功, “介護職員の人手不足問題” 福祉社会研究部。

- 4) Koza, J., “Genetic Programming, On the Programming of Computers by means of Natural Selection”, MIT Press, 1992.
- 5) 平澤宏太郎, 大久保雅文, 片桐広伸, 胡敬煇, 村田純一, “蟻の行動進化における Genetic Network Programming と Genetic Programming の性能比較” 電子学会論文誌 C, vol.121, no.6, pp.1001–1009, 2001.
- 6) 間所洋和, 下井信浩, 佐藤和人, 徐粒, “フィルム荷重センサによる睡眠を見守るヒューマンセンシング,” 日本知能情報ファジィ学会誌 (ヒューマンセンシングとその応用特集号), vol.28, no.6, pp.963–973, 2016.