

ヒューマノイドロボットの複数の全身運動パターンの共通空間の獲得

○学 多谷 浩嗣 (東大) 正 中村 仁彦 (東大, CREST)

Motion Pattern Clustering of Humanoid robot based on NLPCA

*Koji TATANI, Yoshihiko NAKAMURA.

Univ. of Tokyo. 7-3-1, Hongo, Bunkyo-ku, Tokyo

Abstract— For a humanoid robot, fewer parameters might represent its natural motion instead of its high DOF, for the distribution of obtained joint angle is distributed along some hyper curved surface under geometric constraints. Hierarchically arranged NLPCA provides nonlinear basis on such curve surface and gives good performance against dimensionality reduction. We made this NLPCA learns various humanoid motion patterns to get those internal representations in reduced space. This paper reports that common space of motion pattern “walk” is appeared on one dimensional curve which affords motion recognition. Also the identical NLPCA re-generates original motion patterns with the variety from each internal representation.

Keywords: Dimensionality Reduction, NLPCA, Motion Pattern, Humanoid Robot, Common Space

1. はじめに

拘束条件下の運動学を扱うことで、剛体の多リンク系として表現されるヒューマノイドの自然な運動は少数の自由度で表現できることが分かっている¹⁾。逆に自然な運動を行っている際、得られるセンサデータは拘束によりデータ空間中のある曲面上に沿って分布することになる。このときその曲面を構成するより低次元な非線形基底を獲得すれば、その非線形基底上でデータが表現でき、多自由度系の運動パターンを低自由度で表現できる、

砂時計型のニューラルネットはデータが分布する曲面をデータから推定し、その曲面上の座標系への入射関数とその逆関数を与える。元データがもつ位相関係をその曲面上の座標系に反映する低次元化手法であることから、多次元なセンサデータ空間では解析が難しい運動パターンの類似性を低次元空間で評価できる。曲面を構成する非線形基底の選び方は一意でないが、ここでニューラルネットには得られたデータの分散をより大きくする軸を1つ選ぶように学習させる。歩く・蹴る・投げるといった高次元空間での運動パターン間の位相関係がこの特徴軸上に反映されれば、運動パターンの類似性を定量的に評価できる。

本論文では砂時計型ニューラルネットを用いて、多様な全身運動パターンはその低次元空間上でどのような内部表現として現れるかを報告する。特に複数の運動パターンを学習すると、例えば「歩く」という互いに類似の運動パターンから多様性に相当する動きを除いた、言わば「歩く」の共通空間がその特徴軸上に現れるという実験結果について考察する。また共通空間上での内部表現を核に運動の多様性を付加した運動パターンを再現する学習手法について述べる。

2. 運動パターンの低次元化

ヒューマノイドロボットの任意の姿勢は、各関節角を基底とする関節角空間 $\mathcal{J} \subset R^N$ 中の一点 $x \in \mathcal{J}$ として表現することができる。全身の運動パターンを姿勢の瞬間毎のスナップショットの集合と考えれば、運動

は $\mathcal{J}$ における連続した軌道 $O_{\mathcal{J}} = \{x_1, x_2, \dots\}$ として表現される。 $\mathcal{J}$ はヒューマノイドロボットの幾何学的拘束からある曲面上に分布し、曲面を構成する基底でも表現できる。この基底が張る低次元空間 $\mathcal{R} \subset R^M$ が $\mathcal{J}$ の位相関係を保存すれば、 $O_{\mathcal{J}}$ は $\mathcal{R}$ 上でも軌道 $O_{\mathcal{R}}$ として表現される。




Fig. 1 Injection and projection on NLPCA

Fig. 1 の入出力層のユニット数(次元数)が等しい砂時計型ニューラルネット¹⁾は、与えられたデータ集合 $O_{\mathcal{J}}$ に対して恒等写像関数 g を近似する様に学習する²⁾。

$$\hat{x}_i = \hat{g}(x_i) \tag{1}$$

$\hat{g}$ は恒等写像の近似関数を意味する。誤差 $\mathcal{E} = (\hat{x}_i - x_i)^2$ は各層間のユニットを結ぶ重み係数 w をパラメータとして最急降下法により局所最小化される。データ $x_i \in R^N$ はフィードフォワード計算において、入力次元 N よ

¹⁾非線形基底を用いた成分分析を実現する機能的側面から、NLCA(NonLinear Component Analysis) と呼ばれる。特に特徴層のユニットを一つにし順次ユニットを増やし残差を学習させる場合は主成分分析(Principle Component Analysis)の性質を示すことから NLPCA と呼ばれる。

²⁾恒等写像は全空間のサポートが必要条件であるが、砂時計型ニューラルネットワークでは任意の元に対して恒等写像を実現できない。与えられたデータ集合近傍のみ恒等写像関数を近似するものとしてこの表現を選ぶ

り少ない次元 M を持つ特徴層と呼ばれる中間層を通過するため $x' \in R^M$ に射影され、再び $\hat{x} \in R^N$ に復元される事になる。ここで $\hat{g}$ を合成写像 $\hat{g} = h_i \circ h_p$ とすれば、砂時計型ニューラルネットは誤差逆伝播法を用いた反復計算に基づく $\mathcal{E}$ の評価だけで、関節角空間の軌道 $O_{\mathcal{J}}$ を低次元相空間上の曲面 S 上に入射 (injection) する縮約関数 h_i と、 S 上の軌道 $O_{\mathcal{R}}$ を $O_{\mathcal{J}}$ 周辺に射影 (projection) する復元関数 h_p を同時に獲得する特性を持っている。Fig. 1 の 5 層の場合、

$$h_i(x) \equiv f(w_{i2} \sum f(w_{i1}x)) \quad (2)$$

$$h_p(x) \equiv f(w_{p2} \sum f(w_{p1}x)) \quad (3)$$

となる。ここで表記簡略のため $a' = f(a)$ は、ベクトル変数 $a \in R^K$ の各要素に対してシグモイド関数を作させた $a' \in R^K$ を返すベクトル値関数とする。

砂時計型ニューラルネットは x が互いに近い場合、(2)(3) 式におけるシグモイド関数の連続性から x' においてもその位相関係が維持される傾向にある。したがって、運動パターンを表す軌道 $O_{\mathcal{J}}$ は $\mathcal{R}$ においても軌道 $O_{\mathcal{R}}$ として射影される。

3. 複数の砂時計型ニューラルネットの階層的配置

複数の運動パターン学習時における偏りを抑え収束性の向上を狙いとして、複数の砂時計型ニューラルネットを Fig. 2 の様にレベル毎に階層的に配置する。腕・脚の各部位毎に独立したニューラルネットが割り当てられ $\hat{g}$ を局所的に学習させる。ここでセンサデータを直接授受するこのレベルを最下位レベルとする。




Fig. 2 Receptive system and generation system by the identical NLPCA

データフローは縮約時 (受容系) と復元時 (生成系) で異なる。受容系では、まずそれぞれの関節角データ x_i は h_i より縮約され、その時の特徴層でのユニット値 $x' = h_i(x_i)$ は、上位レベルのニューラルネットにおける入力 x_i として参照される。同様の手順の繰り返しにより、最上位レベルのニューラルネットの特徴層において低次元化されたデータが得られる。生成系においては、中間層に直接与えられたデータ x'_i はフィードフォワード計算より出力層での値 $\hat{x}_i = h_p(x'_i)$ に復元される。この $\hat{x}_i$ は下位レベルのニューラルネットの特徴層に x'_i として投射される。この繰り返しより最

下位レベルのニューラルネットの出力層において $\mathcal{J}$ でのデータ $\hat{x}_i$ を得ることが出来る。

このようなニューラルネットの階層的配置に関しては、生体の運動ニューロンの信号伝達経路にも類似の機構があるという解剖学的に興味深い知見がある²⁾。運動ニューロンと筋は互いに独立して発生・分化するが、同じ筋を支配する運動ニューロンは塊となって存在し運動ニューロンプールを形成する。運動ニューロンの分布には規則性があり、四肢を支配する運動ニューロンプールは吻側に、体幹筋を支配するそれは脊髄全長に渡り存在する。これら運動ニューロンは脊髄中枢と筋の情報を選択的に、階層的に中継するというものである。階層的に配置されたニューラルネットは、運動時に腕・脚からの求心性の信号を上位モジュールへ伝達する受容系、中枢からの遠心性の信号を下位モジュールに伝達する生成系、といった視点で運動ニューロンの機能説明をするのに親和性が高いアプローチと言える。




Fig. 3 Reduced internal representation of motion pattern "walk" (top) and its appearance (middle) compared to original motion (bottom)

本手法のニューラルネットの各ユニット値はシグモイド関数 f の特性から $(0, 1)$ をサポートするように設計した。生のセンサデータを直接授受する最下位レベルのニューラルネットの入出力層では、各ユニットが参照するデータは生起範囲として最大値、最小値が更新されながら、常にその最大値、最小値の線形な内分点として区間 $(0, 1)$ 内へスケールされる。運動パターン $O_{\mathcal{J}}$ 上の一姿勢 x_i は区間 $(0, 1)$ の $\mathcal{R}$ 上の一点 x'_i に射影される。Fig. 3 の上段のグラフは、杉原³⁾の方法により生成した力学的に整合性のある歩行動作パターン $O_{\mathcal{J}}^{wk1}$ に対応する、一次元空間上での $O_{\mathcal{R}}^{wk1}$ を表す。横軸のステップ i に対して縦軸が x'_i を意味する。最上位のレベルの特徴層のユニットが一つである事以外は

Fig. 2 と同じ構造のニューラルネットを用意し $O_{\mathcal{J}}^{wk1}$ のみを学習させた．中段は $x'_0, x'_{235}, x'_{483}, x'_{945}$ より復元した姿勢を表す．左右の支持脚を切り替えるタイミングと軌道の極値がほぼ対応している．支持脚時を蹴り抜くまでの動作と遊脚となって同脚を返す動作は $\mathcal{J}$ において近いため，類似の姿勢が過度に低次元化された $\mathcal{R}$ において同一の値に入射される．そのため，動作の切り返し点である蹴り抜いた瞬間が $\mathcal{R}$ の極値として現れると思われる．これから類推されることは，動作パターンが正弦波の様な対称性を持った周期運動であれば， $\mathcal{R}$ にはその位相を反映した軌道が現れる．Fig. 3 下段は，同ステップに対応する元動作 $O_{\mathcal{J}}^{wk1}$ における姿勢である．実機で検証すると， $O_{\mathcal{J}}^{wk1}$ が重心を前に進む様に接地面を蹴るのに対し，復元された動作では，支持脚の蹴りと遊脚の返りをほぼ同じ点に入射していることから，その場で足踏みをするような動作になった．本手法には力学を考慮する機構が無いため，実環境で実現される運動という観点ではその差は大きい．逆に，運動パターンの観点としては歩行動作の特徴的な概形を捉えており，体幹を固定した宙吊りの姿勢では注意して観察しない限り見分けにくい．

この実験結果は，歩行の動作パターンに代表される周期的運動パターンの概形は，適切な非線形基底を選ぶことで，高々 1 次元パラメータの変動で表現できる事を意味する．また，そのような変数を学習から獲得できる事が分かった．

4. 複数の運動パターンの共通空間の獲得

学習すべき運動パターンの増加に伴い，低次元空間においてその内部表現 $O_{\mathcal{R}}^k$ がどのように変化するかを調べた結果を Fig. 4 に示す．一つの歩行パターンのみを学習させた Fig. 3 の結果に加え，前屈みに歩く $O_{\mathcal{R}}^{wk2}$ ，仰け反って歩く $O_{\mathcal{R}}^{wk3}$ ，小股に歩く $O_{\mathcal{R}}^{wk4}$ ，大手を振って歩く $O_{\mathcal{R}}^{wk5}$ ，という複数の歩行運動パターンを用意する．運動データ $O_{\mathcal{J}}^k$ ($k = wk1, wk2, \dots, wk5$) を一組とし，これら全データを均等に学習させる．運動パターンは栗原ら⁴⁾の方法を利用して作成した．モーションキャプチャによる人間の動作を，ヒューマノイドロボットの機構に併せて運動学的に関節角に変換している．




Fig. 4 Internal representation varying with increment of similar walk patterns

砂時計型ニューラルネットは，入出力層におけるデー

タの広がりがある．したがって，多次元な関節角空間 $\mathcal{J}$ の曲面 S 上のデータに対して適切な非線形基底が学習より選ばれば， S 上の分布が $\mathcal{R}$ の区間 $(0, 1)$ の線分上に分散が大きくなるように入射される．二つ目の歩行パターン $O_{\mathcal{J}}^{wk2}$ を学習させた際，各 $O_{\mathcal{J}}^{wk1}, O_{\mathcal{J}}^{wk2}$ を低次元化した軌道は $\mathcal{R}$ 中を互いに棲み分ける様に分布する．これは与えられた全データのスケールにおいて $O_{\mathcal{J}}^{wk1}$ と $O_{\mathcal{J}}^{wk2}$ のクラス間分散が大きく，これが $\mathcal{R}$ の区間 $(0, 1)$ の線分上に距離の大きさとして反映されたと考えられる．同様に $O_{\mathcal{J}}^{wk3}$ を学習した結果も互いに棲み分けが生じる． $O_{\mathcal{J}}^{wk4}$ は $O_{\mathcal{J}}^{wk2}$ ， $O_{\mathcal{J}}^{wk5}$ は $O_{\mathcal{J}}^{wk3}$ の歩行パターンと外見上も類似しており，それらの $\mathcal{R}$ での軌道パターンも近接している．このことから砂時計型ニューラルネットは，運動パターンの類似性を定量的に評価する一手法を与ええる．

また，各歩行パターンを追加した際の $O_{\mathcal{J}}^{wk1}$ に注目すると， $O_{\mathcal{J}}^{wk1}$ を単独で学習した際には $(0.2, 0.6)$ 付近に分布していたが，パターン追加につれて $(0.0, 0.2)$ 付近の分布に変わっている．Fig. 4 の結果は，データの追加とともにが写像される領域が局在化されるという性質が存在するとも解釈できる．




Fig. 5 Internal representation of each motion and corresponding posture of humanoid robot

先の考察からより多数の運動パターンを学習させれば，類似の運動パターンは近接し異なる運動は互いに離れた局所的な軌道として表現されたと考えられる．Fig. 4 の結果に加え，振る $O_{\mathcal{J}}^{sw}$ ，投げる $O_{\mathcal{J}}^{th}$ ，蹴る $O_{\mathcal{J}}^{kc}$ ，しゃがむ $O_{\mathcal{J}}^{sq}$ ，を学習させた結果を Fig. 5 に示す．同図右は左肩の数字 x'_i と対応するロボットの姿勢を表している．特に複数のモーションキャプチャによる歩行パターンに注目すると，これらは全て $(0.4, 0.6)$ の特定の領域に射影されている．過度な低次元化より 1 次元データでは本来の歩行パターンの多様性は再現できないが，逆に，歩行らしい姿勢であればこの領域に入射される，いわば歩行の共通空間と呼ぶことができる．同図下はこの共通空間 $\mathcal{C}_{wk} \subset \mathcal{R}$ の数点に対応する姿勢を表している．

ところで $O_{\mathcal{R}}^{wk1}$ の歩行パターンは他とは大きく離れた位置に射影されている． $O_{\mathcal{R}}^{wk1}$ が力学的整合性を考慮した実環境で歩行可能な動作であるのに対して，それ




Fig. 6 Appearances of original walk (top) and its re-generated walk from 1D orbit (middle) and 3D orbit (bottom)

以外は運動学による幾何学的整合性のみを考慮して生成された歩行動作である．特に重心移動に起因する腰関節まわりの大きなひねりが有る前者と無い後者がこの差を生む大きな要因になっている．蹴る動作 $O_{\mathcal{R}}^{kc}$ の方がモーションキャプチャの歩行パターンより近いものとなってしまうが，腰の動きに注目した場合この結果はデータとして妥当と思われる．

5. 共通空間に対して多様性の付加した運動パターンの生成

過度に低次元化された相空間 $\mathcal{R}$ において局所化が進むと，写像 h_i において多対一の関係性が強くなり，このとき多価関数である h_p において再現性の点では元の姿勢と精度良く対応しない．獲得した $\mathcal{C}_{wk}$ を核とし，プラスアルファとして少数のパラメータで修飾することにより本来の多様な運動パターンを再現できれば， $\mathcal{C}_{wk}$ を共通空間と呼ぶ事に摩擦が少ない．これまで最上位レベルのニューラルネットにおいて特徴層のユニット数を一つにする事で一次元まで行った低次元化を，学習が収束した時点で2つに増やす．この時，新たに加えたユニットに関する重みパラメータだけ新しく追加し，それ以外の元々存在していた重みは変更しない．一次元曲線に入射する事で生じていた誤差 ε を，新しく次元を追加し曲面にすることで吸収させる効果を狙う．




Fig. 7 Comparison of internal representation between dimensionality increment learning and learning with constant number of units

Fig. 7 はユニットを追加した学習時の $\mathcal{R}$ における各運動パターンを示す軌道（左図）と，学習時開始からユニットを二つに固定して学習させた場合のそれ（右図）を表す．前者の手法では共通空間 $\mathcal{C}_{wk}$ の構造を維持しながら，第2軸へ表現を展開していることが分かる．同様に二つのユニットでの学習が収束した時点で，更に一つ追加し収束させた．この時 $O_{\mathcal{J}}^{wk1}$ に関する運

動の様子を Fig. 6 に示す．上段が元の運動，中段が一次元より復元した運動，下段が3次元より復元した運動である．次元数をあげるにより再現精度が向上するのは明白だが，その内部表現は「第一軸の共通空間+第2軸，第3軸の修飾」という見通しの良い構造となっている．

6. おわりに

本論文では，低次元化を実現する砂時計型ニューラルネットを複数用意し，これらを階層的に配置することで多様な運動パターンを単一のモデルで低次元化可能なことを実験より示した．このとき，複数の運動パターンから類似の運動の共通空間をその低次元化された相空間に獲得するという実験結果を得た．運動パターンの類似性を定量的に評価する事ができ，運動のパターン認識に利用することができる．

また共通空間の構造を維持しながら，低次元空間中の軌道と多様な運動パターンを精度良く結びつける手法を述べた．岡田⁵⁾の方法によりこれら軌道をアトラクタをもつ非線形力学系として設計する事で，時間的な運動の変化を表現でき，さらにある運動パターンへの引き込み，運動パターン間の遷移を実現する．今回の結果はまだ議論の余地は多いが，多様の運動パターンを小数のパラメータで表現する問題に対して一つの指針を与える．

なお，本研究は科学技術振興事業団 戦略的基礎研究推進事業の「自律的行動単位の力学的結合による脳型情報処理機械の開発」(代表：中村 仁彦)の支援を受けた．

- 1) 山根克, 中村仁彦. ヒューマンフィギュアの全身運動生成のための協応構造化インターフェース. 日本ロボット学会誌, Vol. 20, No. 3, pp. 335–343, 2002.
- 2) 岡藤辰也, 田中英明. 運動ニューロンのサブタイプ分化とpathfinding. 脳科学のフロンティア - 実験医学, Vol. 20, No. 5, 2002.
- 3) 杉原知道, 西脇光一, 稲葉雅幸, 井上博允. 汎用多リンク系動力学演算ライブラリ「Z-DYNAFORM」の開発. 第18回日本ロボット学会学術講演会予稿集, pp. 1139–1140, 2000.
- 4) K. Kurihara, S. Hoshino, K. Yamane, and Y. Nakamura. Optical motion capture system with pan-tilt camera tracking and realtime data processing. In *Proc. of IEEE International Conference on Robotics and Automation*, Vol. 2, pp. 1241–1248, 2002.
- 5) 岡田昌史, 中村仁彦. N次元時系列パターンを記憶・連想する非線形力学系の多項式表現. 第19回日本ロボット学会学術講演会予稿集, pp. 1229–1230, 2001.