

EMG 信号を利用した全方位型ポインティングデバイス

福田 修[†] 有田 潤^{††} 辻 敏夫^{††}

An EMG-Controlled Omnidirectional Pointing Device

Osamu FUKUDA[†], Jun ARITA^{††}, and Toshio TSUJI^{††}

あらまし 本論文では、EMG 信号を利用した全方位型のポインティングデバイスを提案する。この装置は、使用者をマウスやキーボードの前に拘束しないので、ウェアラブルコンピュータなどの入力デバイスとしても応用が期待できる。ポインタの移動方向推定には、EMG 信号の時系列的な特性を利用するために Recurrent Log-Linearized Gaussian Mixture Network を導入した。このニューラルネットは、動的確率モデルの一つである隠れマルコフモデルに基づいて構成されており、無限に存在するポインタの移動方向を、あらかじめ設定した基準方向への移動確率の組合せとして表現することができる。検証実験を実施した結果、ポインタを精度良く制御可能であることが確認できた。また、従来手法との比較実験により提案手法の有効性が明らかとなった。

キーワード EMG, ポインティングデバイス, リカレントニューラルネット, 隠れマルコフモデル, ウェアラブル

1. ま え が き

本論文では EMG 信号を利用した新しいポインティングデバイスを提案する。人間の筋収縮レベルに応じて発生する EMG 信号は、どのような動作をどのくらいの力で行おうとしているのか、筋の粘弾性はどの程度かなどの有益な情報を含んでおり、これらの情報を効率良く抽出することができれば、これまでにない新しいインタフェース装置を実現できる可能性がある。

EMG 信号から人間の運動意思を推定する研究は、主に電動義手の制御法に関して従来から試みられており [1], [2], 我々もこれまでに、ニューラルネットによる EMG パターンの識別を利用した電動義手やマニピュレータの制御を行ってきた [3] ~ [6]。しかしながら、これらの研究では、電動義手の多自由度制御問題を EMG パターンの動作識別問題に帰着させて考えているため、駆動関節などの自由度はパターン識別のクラス数に限定されていた。これらの手法をポインティングデバイスの操作に直接利用するとどうであろうか。

例えばポインタの移動方向をパターン識別問題に帰着させた場合、ポインタの移動可能方向の総数をあらかじめ設定しなければならず、この数が増えるにつれて膨大な学習サンプル数、学習時間が必要となる。これらの問題に起因し、EMG 信号をポインタの移動に利用する研究は、これまでほとんどなされていない。

我々はこれまでに、ポインタの作業平面上に有限個の基準方向を設定し、その方向に対するポインタの移動確率に基づいて、無限に存在する移動方向を決定する方法を提案してきた [7]。この方法では、基準方向への移動確率の推定に亘る提案した Log-Linearized Gaussian Mixture Network [4] (以下 LLGMN と略記) を利用した。LLGMN は、混合正規分布モデル (Gaussian Mixture Model, 以下 GMM と略記) に基づいて構成されており、その出力は基準方向に対する事後確率に相当する。これにより、LLGMN の出力を各々ベクトルと考えて合成することで、理論的には 360° 全方位へのポインタの移動が期待された。しかしながら、この方法においても、設定した基準方向とそれ以外の方向とで移動方向の推定精度に格差が生じる場合があり、基準方向以外へのポインタ移動は不安定となった [7]。

また、平滑化した EMG 信号の変化には、動作開始から安定するまでの増加フェーズと、安定状態 (安定

[†] (独) 産業技術総合研究所, つくば市

National Institute of Advanced Industrial Science and Technology, 1-2-1 Namiki, Tsukuba-shi, 305-8564 Japan

^{††} 広島大学大学院工学研究科, 東広島市

Graduate School of Engineering, Hiroshima University, 1-4-1 Kagamiyama, Higashi-hiroshima-shi, 739-8527 Japan

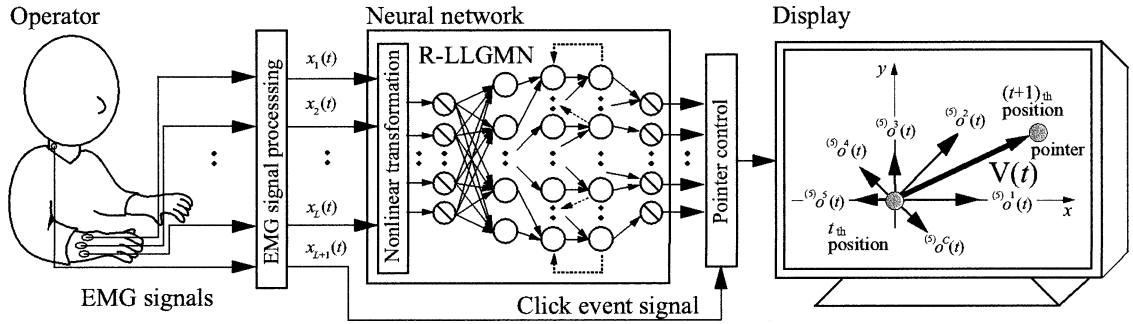


図 1 システム構成
Fig. 1 Structure of the developed system.

フェーズ) から動作終了までの減少フェーズがあり、通常、その変化規模や変化速度は電極ごとに若干異なる傾向が見られる。これは、運動に伴う筋や電極の移動により、筋-電極間の距離 (=電気インピーダンス) が変化したり、計測した EMG に各筋が寄与するバランスが変化したりするためである。このことに起因して EMG パターンの分布は、異動作間でも重複が多くなり、時刻ごとの EMG パターン、すなわち信号の静的な特性だけしかモデル化できない LLGMN では、学習が非常に困難になった。

本論文では、辻らの提案したリカレント構造を有する新しいニューラルネット Recurrent Log-Linearized Gaussian Mixture Network [8] (以下 R-LLGMN と略記) をシステムに導入する。このネットワークは、統計モデルの一つである GMM と、動的な確率モデルの一つである隠れマルコフモデル (Hidden Markov Model, 以下 HMM と略記) を内包した構造を有しており、LLGMN のリカレント版に相当する。時系列データを入力とし、その時系列長が 1 の場合には、LLGMN と同一とみなせる。

R-LLGMN は、各パターンの時系列的なつながりを情報として利用することで、異動作間の重複が多い EMG パターンの分布に対しても精度良く学習を実施することができる。また、学習や推定に用いる入力パターンの時系列長を調節し、情報量をコントロールすることで、基準方向への推定確率を意図的に調節することができる。例えば、推定時に考慮する時系列長を学習時に比べて短くすれば、ネットワークの推定する確率はあいまいになる傾向があり、この性質をうまく利用すれば、基準方向への推定確率を意図的にあいまいにし、その代わりに基準方向以外の方向について推定精度を向上することができる。すなわち、 360° 全

方位への安定したポインタ操作が期待できる。

以下、2. ではシステムの構成について詳説する。次に 3. では、開発したポインティングデバイスについて、健常者・上肢切断者による操作実験を行い、方向精度・操作性を従来手法と比較検討する。最後に 4. にまとめを示す。

2. システム構成

EMG 信号による全方位ポインティングを実現するために、システムを図 1 のように構成した。システムは、EMG 信号処理部、ニューラルネット部、ポインタ制御部の三つのパートからなる。

2.1 EMG 信号処理部

まず、特徴量として複数の筋における筋収縮の協調パターンを EMG 信号から計算する。マルチテレメータ (Web5000 : (株) 日本光電製) で計測した $(L+1)$ チャネル分の EMG 信号を A-D 変換し、チャネルごとに全波整流した後、2 次のデジタルパワースフィルタで平滑化する。ここで、フィルタのカットオフ周波数は、予備実験の結果から 1 [Hz] とした。更にこの信号をサンプリング周波数 100 [Hz] で再サンプリングし、この時系列信号を $EMG_l(t)$ ($l = 1, \dots, L+1$) とする。この $EMG_l(t)$ のうち L チャネル ($l = 1, \dots, L$) は方向推定、1 チャネル ($l = L+1$) はクリックイベントの処理に利用する。

$EMG_l(t)$ ($l = 1, \dots, L$) に関しては、 L チャネルの和が 1 となるように次式に従って正規化したものの特徴パターン $x(t) = [x_1(t), x_2(t), \dots, x_L(t)]^T \in \mathcal{R}^L$ として R-LLGMN へ入力する。

$$x_l(t) = \frac{EMG_l(t) - \overline{EMG}_l^{st}}{\sum_{l'=1}^L (EMG_{l'}(t) - \overline{EMG}_{l'}^{st})} \quad (1)$$




図 2 R-LLGMN の構造
Fig.2 Structure of the R-LLGMN.

ここで \overline{EMG}_l^{st} は安静時における $EMG_l(t)$ の時間平均である。

$EMG_{L+1}(t)$ に関しては計測部位を L チャンネルとは別の部位 (例えば首部) とし, この値を最大筋収縮時の値で正規化したものをクリック信号 $\beta(t)$ とする. この値が設定したしきい値を超えたときにクリックイベントが発生したと判定する.

2.2 ニューラルネット部

ニューラルネット部では, EMG 信号処理部で計算した使用者の EMG パターン $x(n)$ ($n = t - T + 1, \dots, t$) からポイントの各基準方向への事後確率を推定する. ここで T は入力パターンの時間方向への長さとする. この計算には辻らが提案した R-LLGMN [8] を用いる. このネットワークは, 統計モデルの一つである GMM と, 動的な確率モデルの一つである HMM を構造として内包しており, 使用者の EMG 信号の時系列的な特性を学習により獲得することができる. 図 2 は, ネットワークの構造を示している. この構造の中に, クラス数 C , 各クラスの状態数 K_c , クラス c , 状態 k に対応する混合ガウス分布モデルのコンポーネント数 $M_{c,k}$ の HMM を含んでいる.

前向き計算では, まず, 入力ベクトル $x(t)$ を次式に従って非線形変換し, 新たな入力ベクトルとして用いる.

$$\mathbf{X}(t) = [1, \mathbf{x}(t)^T, x_1(t)^2, x_1(t)x_2(t), \dots, x_1(t)x_L(t), x_2(t)^2, x_2(t)x_3(t), \dots, x_2(t)x_L(t), \dots, x_L(t)^2]^T \quad (2)$$

第 1 層は $H = 1 + L(L + 3)/2$ 個のユニットから構成

され, 恒等関数を入出力関数として用いている. この新たな入力ベクトル $X_h(t)$ ($h = 1, 2, \dots, H$) は, そのまま $(1)O_h(t)$ として出力される.

第 2 層のユニット $\{c, k, k', m\}$ ($c = 1, \dots, C$; $k, k' = 1, \dots, K_c$; $m = 1, \dots, M_{c,k}$) は, 第 1 層のユニットの出力に重み係数 $w_{k',k,m,h}^c$ が掛け合わされたものを受け取る. 第 2 層の入出力関係は,

$$(2)I_{k',k,m}^c(t) = \sum_{h=1}^H (1)O_h(t)w_{k',k,m,h}^c \quad (3)$$

$$(2)O_{k',k,m}^c(t) = \exp((2)I_{k',k,m}^c(t)) \quad (4)$$

となる.

第 3 層のユニット $\{c, k, k'\}$ への入力は, 第 2 層のユニット $\{c, k, k', m\}$ ($m = 1, \dots, M_{c,k}$) の出力を統合したものである. また, その入力に 1 時刻前の第 4 層の出力を乗じた値が第 3 層の出力となる. 第 3 層の入出力関係は,

$$(3)I_{k',k}^c(t) = \sum_{m=1}^{M_{c,k}} (2)O_{k',k,m}^c(t) \quad (5)$$

$$(3)O_{k',k}^c(t) = (4)O_{k',k}^c(t-1)(3)I_{k',k}^c(t) \quad (6)$$

となる. ただし, 初期状態では $(4)O_{k',k}^c(0) = 1.0$ とする.

更に第 4 層は第 3 層のユニット $\{c, k, k'\}$ の出力を統合したものを受け取る. 入出力関係は,

$$(4)I_k^c(t) = \sum_{k'=1}^{K_c} (3)O_{k',k}^c(t) \quad (7)$$

$${}^{(4)}O_k^c(t) = \frac{{}^{(4)}I_k^c(t)}{\sum_{c'=1}^C \sum_{k'=1}^{K_{c'}} {}^{(4)}I_{k'}^{c'}(t)} \quad (8)$$

で与えられる．

最後に、第 5 層のユニット c は第 4 層の K_c ユニット $\{c, k\}$ ($k = 1, \dots, K_c$) の出力を統合したものである．入出力関係は、

$${}^{(5)}I^c(t) = \sum_{k=1}^{K_c} {}^{(4)}O_k^c(t) \quad (9)$$

$${}^{(5)}O^c(t) = {}^{(5)}I^c(t) \quad (10)$$

となる．この出力 ${}^{(5)}O^c(t)$ が基準方向 c に対する事後確率となる（図 1 参照）．

以上のように、このネットワークは、第 3 層と第 4 層の間にリカレント結合を有することで、1 時刻前の出力を考慮することができる．また、第 1 層と第 2 層の間の重み係数 w を学習的に調節するだけで、基準方向に対する事後確率を HMM に基づいてモデル化することができる．

R-LLGMN は、 C 個の基準方向 ϕ それぞれに用意された L 個の時系列信号 ($N = L \times C$) を学習データとして学習を行う．ただし、 ϕ は図 1 の x 軸正方向を 0 とし、反時計回りに増加するよう定義する．学習用データに対するネットワークの評価関数 J は、

$$J = \sum_{n=1}^N J_n = - \sum_{n=1}^N \sum_{c=1}^C T_c^{(n)} \log {}^{(5)}O^c(t)^{(n)} \quad (11)$$

と定義し、これを最小化、すなわち対数ゆう度を最大化するように学習を行う．ただし、 ${}^{(5)}O^c(t)^{(n)}$ は入力ベクトル $x(t)^{(n)}$ に対する時刻 t での出力を意味している． $T_c^{(n)}$ は教師信号であり、対応するクラスには 1 を、それ以外のクラスには 0 を与える．重みの更新には、通時的誤差逆伝搬学習法 (BPTT) を用いる [9]．

学習時間は「教師信号を抽出する時間」と「ネットワークの重み調節時間」の合計と考えることができ、本手法は主に前者の時間削減に有効である．教師信号抽出に要する時間は、1 方向につき約 5 秒程度が必要で、本手法では、 $C = 4$ 、 $L = 20$ の場合で長く見積もっても 30 秒程度となる．これに対し、従来法 [7] の場合は多くの方向に対して教師信号を抽出していたため、その分学習時間が必要であった．ネットワークの重み調節時間については、操作者の精神的負担を少しでも軽減することを目的として、ターミナルアトラク

タ (Terminal Attractor, 以下 TA と略記) を学習則に導入し、収束時間の上限値を設定可能とした [8]．この時間は前記条件で数秒程度である (CPU Pentium 4.0, 2.6 G の場合)．

2.3 ポインタ制御部

ここでは、R-LLGMN の出力及び推定した筋活動レベルをもとにポインタの動きを計算する．R-LLGMN の出力は、図 1 に示すように各基準方向 c へポインタが移動する可能性を示している．そこで時刻 t の EMG パターンによるポインタの移動方向ベクトル $e(t) = (e_x(t), e_y(t))^T$ を、以下のように定義する．

$$e_x(t) = \frac{v_X(t)}{\sqrt{v_X^2(t) + v_Y^2(t)}} \quad (12)$$

$$e_y(t) = \frac{v_Y(t)}{\sqrt{v_X^2(t) + v_Y^2(t)}} \quad (13)$$

$$v_X(t) = \sum_{c=1}^C {}^{(5)}O^c(t) \cos(2\pi(c-1)/C) \quad (14)$$

$$v_Y(t) = \sum_{c=1}^C {}^{(5)}O^c(t) \sin(2\pi(c-1)/C) \quad (15)$$

ここで、 $v_X(t)$ 、 $v_Y(t)$ は各基準方向へ対応するベクトルの x 成分、 y 成分を示す．

また筋活動レベル $\alpha(t)$ を以下のとおり計算する．

$$\alpha(t) = \frac{\sum_{l=1}^L EMG_l(t) - \overline{EMG}_l^{st}}{\sum_{c=1}^C \overline{EMG}_c^{max} {}^{(5)}O^c(t)} \quad (16)$$

ここで \overline{EMG}_c^{max} は各基準方向に対する最大随意筋収縮時の EMG 信号のチャンネル和を時間平均したものである．

使用者の力特性に合ったポインタの操作感覚を実現するためには、我々が日常経験する物理的法則に従ったポインタの運動が適すると考えられる．そこで、筋活動レベル $\alpha(t)$ と移動方向ベクトル $e(t)$ に基づき、以下のインピーダンスモデルを用いてポインタがどのように移動するかを計算する．

$$M_e \ddot{p}(t) + B_e \dot{p}(t) = F(t) \quad (17)$$

M_e 、 B_e はそれぞれ慣性、粘性パラメータで、 $p(t)$ はポインタの位置ベクトルである．また $F(t)$ はポインタに加える駆動力で、 $\alpha(t)$ 、 $e(t)$ から 0 次ホールドを用いて計算する．

$$F(t) = \begin{cases} g\alpha(t)e(t) & (\alpha(t) \geq \alpha_0) \\ 0 & (\alpha(t) < \alpha_0) \end{cases} \quad (18)$$

ただし、 g はカゲインを表す． α_0 はポインタ操作の有無を判定するしきい値である．式 (17) は粘性摩擦 B_e を有する空間に置かれた質量 M_e の物体に力 $F(t)$ が加わった際の運動方程式を表している．このような物理モデルに従い、数値積分によってポインタの位置、速度を計算することで、操作者の力感覚に対応した自然な操作感が期待できる．

3. 実 験

構築したシステムの操作性を調べるための実験を行った．被験者は6名で、被験者 A, B, C, D, E については、いずれも健康な男子大学生 (22 歳, 23 歳, 22 歳, 22 歳, 24 歳) とした．被験者 F は男性 (45 歳) で 4 年前に事故のため右手首から 15 cm ほどの部位で前腕部を切断している．どの被験者も事前に十分な練習を行った．

EMG 信号計測用の電極 (NT-511G, NT-512G : (株) 日本光電製) は材質が Ag/AgCl, 形状が直径 0.012 [m] の円形、双極差動型のものを用いた．健康者の場合の使用数は、7ch で右前腕部に 6ch (橈側手根伸筋, 橈側手根屈筋, 尺側手根伸筋, 尺側手根屈筋, 浅指屈筋, 固有示指伸筋), 左前腕部に 1ch (橈側手根伸筋) を装着した．切断者の場合は、8ch で切断された前腕部の残存筋に 7ch, また、左前腕部 (橈側手根伸筋) に 1ch を装着した．いずれも左前腕の電極は、クリックイベント発生用である．ただし、これらの電極の装着位置に関しては、ある程度自由に装着してもシステムに導入したニューラルネットにより適応が可能である．フィールドで使用する際には、EMG 信号に関して知識不十分な使用者も想定され、特定の筋の上に電極を装着することが困難と考えられるので、このような適応機能が有効と考えられる．

実験では、ポインタの移動方向を右手首の曲げ方向に対応させてニューラルネットの学習を行った．ただし、切断者の場合は脳内に残された手首の運動イメージによりマウスを操作するように指示した．R-LLGMN のパラメータであるコンポーネント数、状態数は、それぞれ、 $M = 1, K = 1$, 学習に用いた基準方向は、 $\phi = 0$ から $\frac{\pi}{2}$ rad 大きさの 4 方向と設定した．インピーダンスモデルのパラメータである M_e, B_e は、予

備実験の結果を踏まえ操作者の操作感覚に合う値を設定した．なお本実験では、ディスプレイのサイズは 17 インチ、解像度は 640×480 とした．ディスプレイは操作者正面の卓上に置かれており、操作者は椅子に直立姿勢で座り、手首を自然に卓上 (ただし卓とは非接触) に出した位置で操作を行った．健康者の場合、掌は軽く握った状態とした．

3.1 操 作 例

図 3 に被験者 F (上肢切断者) による操作例を示す．ここでは、ディスプレイ上にランダムにいくつかの円を配置し、その円を順番にクリックするタスクを実行している．R-LLGMN 学習時の時系列長は 20 とし、推定時の時系列長は 5 とした．図 (a) はディスプレイ上のポインタの軌跡、(b) は制御中の信号処理の様子を示しており、上から順に EMG 信号、筋活動レ

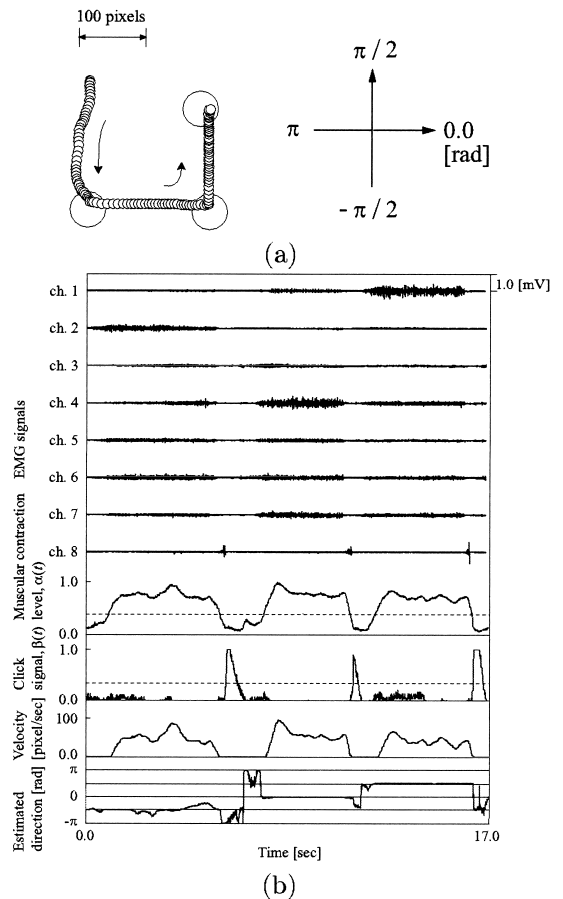


図 3 上肢切断者 F による操作例
Fig. 3 An example of pointer control by the amputee F.

ベル $\alpha(t)$, クリック信号 $\beta(t)$, ポインタの移動速度, 移動方向を示している. 本システムが, 上肢切断者に対してもスムーズなポインティングを提供可能なことが分かる.

3.2 方向精度

開発したシステムの全方位への方向精度の検証を行った. 各被験者には, ディスプレイによるフィードバックのない状態で, 手首を $\frac{\pi}{8}$ rad きざみの 16 方向に各方向 2 秒間動作するよう指示した. そして, このとき計測した EMG 信号から推定したポインタ移動方向と操作者への指示方向との誤差を評価指標として計算した.

図 4 に実験結果を示す. ここで方向精度には, 学習方向, 未学習方向で違いが見られたため, 学習した 4 方向と未学習の 12 方向に分けて計算を行った. それぞれ (a) 学習方向, (b) 未学習方向の誤差平均であり, 被験者は A, B の結果である. 各図では, 学習時, 推定時に入力する特徴パターンの時系列長を, 1 きざみで 1 から 40 までの計 1600 通りに変化させて誤差平均を算出している. この図より, 学習時の時系列長が長く, 推定時の時系列長が短くなるにつれて, 学習した方向では誤差が増加し, 未学習の方向では減少することが分かる. これは, 推定時の時系列長が学習時のそれよりも短くなることで, 情報が低下し, R-LLGMN からの事後確率の出力があいまいになったためである. この結果より, 全方位への精度を平均的に向上させるためには, 学習した方向の誤差が増大してしまうものの, 推定信号は短い方が良いことが分かる. 以下では, 学習時の時系列長を 10, 推定時の時系列長を 1 とし て操作を行うこととする.

次に, R-LLGMN における方向推定精度の有効性を示すために, LLGMN, Back Propagation Neural Network (以下 BPNN と略記) を利用した場合のシステムとの比較実験を行った. LLGMN は, GMM を構造として導入しており, R-LLGMN からリカレント結合を除いた場合に相当する. 被験者にはディスプレイによるフィードバックのある状態で, 16 方向のうちいずれかの指定された方向にポインタを移動するよう に指示し, その際の方向推定精度を求めた.

この実験において, LLGMN のコンポーネント数,

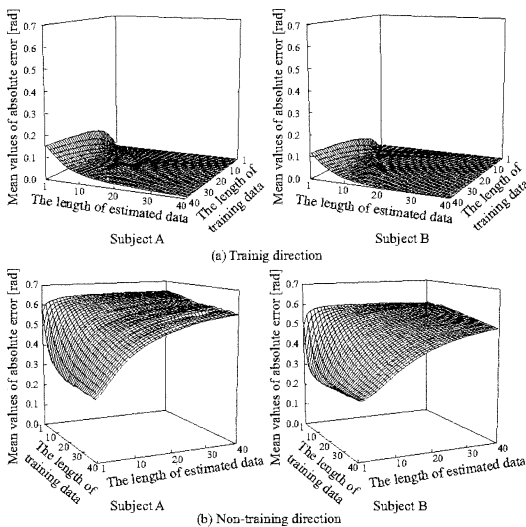
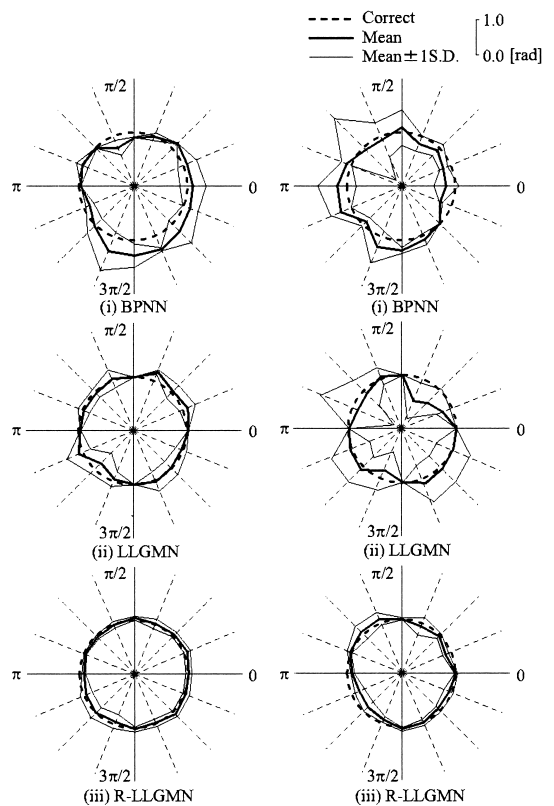


図 4 学習時と推定時の時系列長による推定方向の誤差の変化

Fig. 4 Effects of the length of the training data and the length of the estimated data on the direction error.



(a) Subject A

(b) Subject B

図 5 推定方向の正確性 (被験者 A, B)
Fig. 5 Accuracy of the estimated direction (Subject A, B).

ターミナルアトラクタのパラメータは R-LLGMN のそれらと同数に設定した。BPNN のユニット数に関しては、方向推定精度が高くなるように、入力層 6, 第 2 層 7, 第 3 層 6, 出力層 4 と試行錯誤的に決定した。なお、ポインタの移動方向推定処理では、BPNN 出力の総和が 1 となるように正規化し、R-LLGMN の場合と同様の方法で方向推定を実施した。学習の評価関数には、教師信号との二乗誤差を利用し、学習率、慣性係数、学習終了誤差しきい値のパラメータをそれぞれ 0.01, 0.001, 0.0003 とした。

図 5 に被験者 A, B による結果を示す。各レーダチャートは指定方向を示してから 2 秒間における、誤差の平均と標準偏差を表しており、(i) は BPNN, (ii) は LLGMN, (ii) は R-LLGMN の結果である。この図から、R-LLGMN は BPNN や LLGMN に比べて方向精度にばらつきがなく、すべての方向について精度良く推定が行えていることが分かる。なお、同様の実験における被験者 D, E, F の結果 (全方向の平均誤差 [rad] を BPNN, LLGMN, R-LLGMN について計算) は、被験者 D の場合で 0.177, 0.127, 0.072, 被験者 E の場合で 0.442, 0.175, 0.125, 被験者 F の場合で 0.255, 0.124, 0.067 となっており、いずれも R-LLGMN の有効性が明らかとなった。

3.3 操作性

最後に、提案手法の操作性を評価するための実験を行った。被験者に提示したタスクを図 6 に示す。ディ

スプレイには (a) から (f) のタスクが順番に提示され、被験者はディスプレイ上に表示された 2 点間を往復するタスクを実行した。なお、図におけるポインタの大きさ、ターゲットの大きさ、ポインタとターゲットの距離、それぞれの比率はディスプレイに表示されるものと同じ割合にしてある。2 点間の距離は 400 pixels で、ポインタの移動方向は $\frac{\pi}{6}$ rad きざみの 6 方向とし、往復操作における操作時間、最短軌道からのずれの積分値を計算した。6 方向すべてに対する操作を 1 セッションとし、5 セッションのデータの平均値、標準偏差を求めた。R-LLGMN, LLGMN, BPNN の設

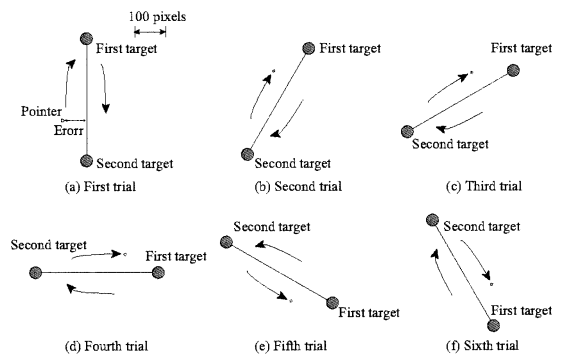


図 6 比較実験の方法：被験者はポインタでターゲット間を往復する作業を実施する。

Fig. 6 A condition of the comparative experiment: the subject controls the pointer between the first target and the second target.

表 1 比較実験の結果：図 6 の条件において 3 種類のニューラルネットワークを比較した。
Table 1 The results of comparative experiment: three neural networks were compared on condition shown in Fig. 6.

(a) Time for pointer manipulation [s]

	BPNN	LLGMN	R-LLGMN
Subject A	5.1±0.2**	5.3±0.2**	4.7±0.1
Subject B	5.7±0.2**	5.5±0.4**	4.7±0.1
Subject C	7.0±0.3**	7.1±0.2**	6.0±0.2
Subject D	6.0±0.7	6.4±0.1	6.2±0.5
Subject E	7.3±0.7*	7.0±0.4	6.6±0.5

*...5% **...1%

(b) Integration of the distance error between pointer and the desired track [pixel]

	BPNN	LLGMN	R-LLGMN
Subject A	161.4±25.4 **	154.2±9.5**	95.6±18.1
Subject B	347.8±55.9 **	218.6±57.9 *	142.1±24.9
Subject C	317.8±16.9 **	295.5±27.9 **	212.0±35.1
Subject D	211.3±27.2	223.3±20.1 *	183.4±31.2
Subject E	498.0±114.8 **	364.8±48.3	304.4±68.9

*...5% **...1%

定は 3.2 と同様とした。なおこの実験は、本手法が基準方向以外に関しても高精度な操作性を実現できることを示すためのもので、タスクにおけるポインタ移動方向には基準以外の方向を意図的に多く含めた。

表 1 に実験結果を示す。(a) は往復操作の平均時間、(b) は最短軌道からのずれの積分値を示している。また、R-LLGMN の結果を基準に、BPNN, LLGMN の結果を検定した(片側検定)。ここで、危険率 5, 1% で有意差ありと判定された結果にはそれぞれ *, ** 印を表中に示す。各手法を比較すると、R-LLGMN が平均時間、軌道誤差ともに小さくなる傾向となっており、操作性が最も高いことが確かめられた。

4. む す び

本論文では、新しいポインティングデバイスの開発を目的とし、EMG 信号を利用した全方位型のポインティングデバイスを開発した。開発したシステムは、無限に存在するポインタの移動方向を有限個の基準方向の組合せによって表現することで、任意の方向へポインティングが可能である。また、R-LLGMN をシステムに導入することで、特徴パターンの時系列長を変化させることにより全方位への高い方向推定精度を実現した。

今後は、より詳細な操作性の評価を検討するとともに、信号の新たな前処理法の開発、実用レベルでのシステム構築を行う予定である。

文 献

- [1] D. Graupe, J. Magnussen, and A.A.M. Beex, "A microprocessor system for multifunctional control of upper limb prostheses via myoelectric signal identification," *IEEE Trans. Autom. Control*, vol.23, no.4, pp.538-544, Aug. 1978.
- [2] M.F. Kelly, P.A. Parker, and R.N. Scott, "The application of neural networks to myoelectric signal analysis," *IEEE Trans. Biomed. Eng.*, vol.37, no.3, pp.221-230, 1990.
- [3] 辻 敏夫, 森大一郎, 伊藤宏司, "統計構造を組み込んだニューラルネットによる EMG 動作識別法," *電学論 (C)*, vol.112-C, no.8, pp.465-473, 1992.
- [4] 辻 敏夫, 市延弘行, 金子 真, "混合正規分布モデルを用いたフィードフォワード型ニューラルネット," *信学論 (D-II)*, vol.J77-D-II, no.10, pp.2093-2100, Oct. 1994.
- [5] O. Fukuda, T. Tsuji, and M. Kaneko, "An EMG controlled robotic manipulator using neural networks," *Proc. IEEE International Workshop on Robot and Human Communication*, pp.442-447, 1997.
- [6] O. Fukuda, T. Tsuji, M. Kaneko, and A. Otsuka, "A human-assisting manipulator teleoperated by EMG signals and arm motions," *IEEE Trans. Robot. Autom.*, vol.19, no.2, pp.210-222, 2003.
- [7] O. Fukuda, T. Tsuji, and M. Kaneko, "An EMG controlled pointing device using a neural network," *Proc. IEEE International Conference on Systems, Man and Cybernetics*, vol.4, pp.63-68, 1999.
- [8] T. Tsuji, N. Bu, O. Fukuda, and M. Kaneko, "A recurrent log-linearized Gaussian mixture network," *IEEE Trans. Neural Netw.*, vol.14, no.2, pp.304-316, 2003.
- [9] P.J. Werbos, "Backpropagation through time: What it does and how to do it," *Proc. IEEE*, vol.78, no.10, pp.1550-1560, 1990.
- [10] M. Zak, "Terminal attractors for addressable memory in neural networks," *Phys. Lett. A*, vol.133, pp.18-22, 1988.

(平成 15 年 9 月 10 日受付, 16 年 3 月 10 日再受付)



福田 修 (正員)

2000 広島大学大学院工学研究科博士課程後期了。1997 年 4 月～1999 年 3 月の期間、日本学術振興会特別研究員(DC1)。2000 通商産業省工業技術院機械技術研究所入所, 2001 独立行政法人産業技術総合研究所へ転任。現在に至る。博士(工学)。ニューラルネット, ヒューマンインタフェース, 電動動力義手などの研究に従事。日本機械学会, 日本人間工学会, 日本ロボット学会等各会員。



有田 潤

2003 広島大学工学部第 2 類(電気系)卒, 現在, 同大学院工学研究科博士課程前期複雑システム工学専攻在学中。筋電位信号を利用したインタフェースに関する研究に従事。



辻 敏夫 (正員)

1985 広島大学大学院工学研究科博士課程前期了。同年広島大学工学部助手。1994 同助教授を経て, 2002 より同大学院工学研究科教授, 現在に至る。工博。計測自動制御学会学術奨励賞(1986), 論文賞(2002), バイオメカニズム学会論文賞(1990), 日本義肢装具学会論文賞(2000), 日本医科器械学会論文賞(2003)などを受賞。人間とロボットの運動制御, 生体信号解析, ニューラルネット, ヒューマン・マシンシステムなどの研究に従事。