

## ニューロ動作解析手法を用いたスポーツ技能評価の一考察 A Consideration on Sport Skill Evaluation Using Motion Analysis Model by Neural Network

林 勲  
Isao Hayashi  
関西大学  
Kansai University

前田 利之  
Toshiyuki Maeda  
阪南大学  
Hannan University

藤井 政則  
Masanori Fujii  
阪南大学  
Hannan University

王 碩玉  
Shuoyu Wang  
高知工科大学  
Kochi University  
of Technology

田阪 登紀夫  
Tokio Tasaka  
同志社大学  
Doshisha University

田阪 昌英  
Masahide Tasaka  
日本卓球協会  
Japan Table  
Tennis Association

*Abstract* In this paper, we discuss sport technique evaluation using motion analysis model by neural networks and data mining methods. For students of university, we recorded the continuous forehand stroke by the table tennis in the video frames, and analyzed the trajectory pattern of nine marking points attached at subject's body with a coach's technique evaluation and the motion analysis model. As a result, we obtained some technique rules classified member of table tennis club, middle level player and beginner as fuzzy rules, and also estimated the movement of the marking points to improve in table tennis technique.

### 1. はじめに

人間の動作と技能研究において、技能スキルは人の意図した単機能成果を生成する単機能技能と環境変化に適応したメタ技能との階層構造から構成されている [1, 2]。松本ら [2] は、企業での高度な熟練性を有した熟練工は、それらの階層的な技能構造を明確な内部モデルとして持ち、状況に応じて内部モデルから行動プロセスを決定していると論じている。しかし、どのような技能者であっても自らの内部モデルを完全に理解することは困難であり、通常は、自らの表象行動を客観的に観察して、内部モデルを微調整して高度な技能スキルを達成する。このように、単機能技能からメタ技能、表象行動への意図表現のボトムアップ処理、及び、表象行動からメタ技能、単機能技能への微調整のトップダウン処理とが潤滑に機能して、内部モデルを高精度化し熟練性が達成される。

一方、スポーツの技能動作の研究では、動作計測や生理的計測から身体的構造モデルや骨格構造モデルを用いる研究 [3-6] が推進されている。望月ら [4] は、「人工物上で再現される技能」を「人工技能」と定義し、DLT(Direct Linear Transformation)法による3次元動作計測技術を用いて身体的構造モデルを構築し、プロ野球投手の最適投球動作のメカニズムを解明している。また、葛西ら [5] もDLT法を卓球フォアハンド動作に適用し、3次元解析プログラムにより身体部位の軌跡を求め、初心者指導の基礎的資料を作成している。宮木ら [6] は、動作解析手法により、卓球フォアハンドストロークでの経験的「タメ」について議論している。

本論文では、スポーツ動作として卓球のフォアハンドストローク [5, 6] を例にとり、身体的構造モデルや骨格構造モデルを用いることなく、ニューラルネットワークの数理モデルを用いて内部モデルを同定する。ニューラルネットワークを卓球動作の解析に用いた研究には、Perlら [7] が、Kohonen Feature Mapを用いて卓球試合でのボールの軌跡を解析し戦略構造を同定している。本論文では、卓球の技能スキルに着目し、被験者による卓球のフォアハンドストロークを動画で解析して、その熟練性を上級者、中級者、初級者の3段階で評価し、TAMネットワーク [8] とデータマイニング手法を用いて内部モデルを同定する。まず、卓球部の上級者7名、卓球経験者の中級者3名、初級者5名の合計15名の大学生に対して、シェイクハンドラケットによるフォアハンドの打球軌跡を高速度カメラで撮影し、被験者9名による右上腕の9点のマーキング測定点での位置座標と速度の時系列データ、及び3段階の熟練性の評価値から観測データ集合を構成した。次に、統計的手法により被験者のフォアハンドストロークの技能レベルの類似性と相違性について議論した。さらに、数理モデルとしてTAMネットワークとC4.5, Native Bayes Tree, Random Forestを用いて、技能スキルの内部モデルを同定し、単機能技能とメタ技能の熟練性との関係について議論した。最後に、卓球指導者による表象行動に対する助言を参考にし、熟練性を向上させるための単機能技能とメタ技能を観測マーキングの重要度とファジィルールとして獲得した。

## 2. 卓球のフォアハンドストロークの分析

スポーツの動作解析の研究では、身体に装着した針筋電により筋線維が興奮する際の活動電位を記録する筋電図検査 [9] や身体に装着した複数の観測点によるマーキング観測法 [10] 等により、身体的構造や骨格構造を明らかにすることを課題とした。本研究では、技能スキルは身体各部位の単機能技能とその上位層のメタ技能による階層構造の内部モデルから構成されていると仮定し、身体的構造や骨格構造を議論することなく、観測された画像データと表象行動に対する技能評価から数理モデルを用いて内部モデルを同定する。ここでは、スポーツとして卓球を取り上げ、被験者のフォアハンドストロークによる動作軌跡の観測データと表象行動の技能評価から、TAM ネットワークを用いて卓球技能のスキルを解析する。本システムの構造を図 1 に示す。

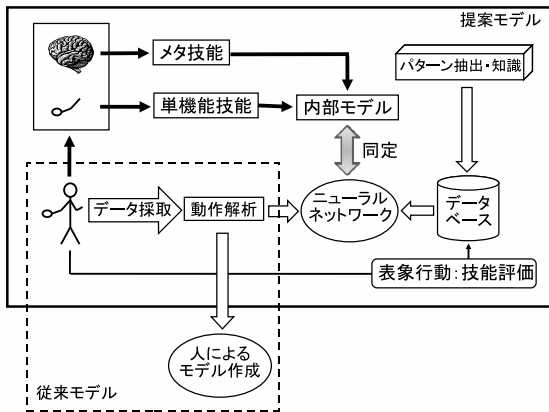


Fig. 1: Proposed System




Fig. 2: Measurement Markings

実験では、被験者として阪南大学の男子学生 15 名を選定した。表象行動の技能評価として、阪南大学卓球部に所属する 7 名を上級者、中学校と高校において卓球部所属であった 3 名を中級者、全くの卓球競技の経験がない 5 名を初級者として分類した。

実験試技では、観測データのマーキング測定点として

被験者の右上腕に 9 個所のマーキング点 ((1) 肩鎖関節点, (2) 肩峰点, (3) 橈骨点, (4) 尺骨点, (5) 橈骨茎状突起最下 endpoint, (6) 尺骨茎状突起最下 endpoint, (7) ラケット側端内向点, (8) ラケット側端外向点, (9) ラケット上端点) を施した。図 2 に測定マーキングの設定位置を示す。

被験者の対角線延長上の卓球台エンドラインから約 30cm の距離に配球マシン (ヤマト卓球 (株), TSP52050) を設置し、仰角 20 度、速度レベル 25、ピッチレベル 30 で、ボールを配球した。被験者は、卓球台エンドラインから 75cm 内側に着地した配球ボールを相手コートにフォアクロスに返球する。フォアハンドストロークの動作軌跡の観測には、高速度カメラ ((株) デジモ社, VCC-H300, 分解能:  $512 \times 512 \text{ pixel}$ , フレームレート:  $90 \text{ fps}$ ) を用いて、被験者前方 360cm, 高さ 130cm に設置した。被験者がフォアハンドで打球している間に、観測時間: 10 分間で各被験者の数回分のフォアハンドストロークを撮影した (図 3 参照)。




Fig. 3: Pictures of Subject

撮影された連続画像から、配球されたボールに対して、被験者がテイクバックを開始した時点のフレームからフォアハンドストロークを振り切った時点のフレームまでの約 40 フレームから 120 フレームまでの静止画像を抽出した。その後、各フレーム画像において、第 1 フレームの被験者の肩の位置を原点として、被験者に装着した 9 点の観測マーキングの 2 次元  $(x, y)$  座標を抽出した。一例として、上級者、中級者、初級者の観測マーキングの 2 次元座標と水平方向  $(x)$  での速度を図 4 と図 5 に示す。また、図 4 のマーキング 1 番 ( $M1$ ), 4 番 ( $M4$ ), 9 番 ( $M9$ ) の水平方向  $(x)$  の座標位置の最小値と最大値を表 1 に示す。

図 4 と図 5、及び表 1 から、次の結論が得られた。

- 上級者間では、 $M1 \sim M9$  の位置の座標が極めて一致した。相関係数は  $x = 0.985, y = 0.790$  であった。上級者は、同じような軌道でラケットを振る熟練の技能スキルを習得していると言える。また、軌道がゆらぎのない楕円を描いていることから、上級者はスムーズなフォアハンドドライブで返球していることがわかる。

Table 1: Min and Max Position of x-Direction of Markings

	M1		M4		M9	
	最小値	最大値	最小値	最大値	最小値	最大値
上級者	-3	114	-29	254	-267	372
中級者	-10	116	-25	236	-218	577
初級者	-33	152	-50	239	-214	697

- 上級者の速度から、全観測マーキングでラケットにボールが当たる瞬間の速度が最大となり、テイクバック（負の速度）からフォアスロー（正の速度）までが滑らかに変化していることがわかる。すなわち、ラケットにボールが当たるインパクトで最大速度を出せるように滑らかな速度を実現する技能スキルを習得していると言える。
- 中級者間では、M1~M9の位置の座標は一致している個所もあったが、異なる個所も見られた。相関係数は  $x = 0.919, y = 0.607$  であった。軌道に多少のゆらぎがあり、過去に卓球の技能を習得しているので、上級者には及ばないが、中級者間で類似軌道を描いていることがわかる。しかし、フォアハンドドライブの軌道ではないことがわかる。
- 中級者の速度から、ラケットにボールが当たる瞬間で速度が最大となっている。しかし、M7とM9の速度分布は双峰形となっており、ラケットをボールに当てるためインパクトの瞬間で速度を微調整していることがわかる。
- 初級者間では、M1~M9の位置座標が一致している個所もあったが、多くは場合、異なる形状を示した。相関係数は  $x = 0.073, y = -0.04$  であった。特に、M1での位置座標は初級者間で異なっており、軌跡の範囲が大きい。上級者や中級者に比べて、肩が動いていることがわかる。また、M7とM9での位置座標は初級者間で大きく異なり、一定の軌跡を描いていない。これらの結果から、初級者のラケットの振り方には、千差万別の振り方があることがわかる。
- 初級者の速度から、M3~M9において、ラケットにボールが当たる前でほぼ速度を停止し、ボールが当たる瞬間で速度をあげる動作、いわゆる「ラケットでボールを迎えに行く動作」が見られた。また、M1において、上級者や中級者に比べて全時間帯で速度が検出され肩が大きく動いていることがわかる。さらに、M7とM9の速度がゼロの時間帯でもM1やM4で速度が観測されることから、ラケットの移動に対して肩や肘が動く、いわゆる「体が開く動作」が見られる。
- 上級者は、表1から、ラケットを水平方向に幅を小さくコンパクトに振り、図5から、ボールに当たる瞬間だけ速度を最大にする技能スキルを習得していることがわかる。初級者は、水平方向の幅が大きいにも関わらず、インパクトの前でラケッ

トの振りを減速して、体を開き、ボールを迎えに行っていることがわかる。中級者は上級者と初級者の中間の技能スキルである。

- 全ての結果から、上級者や中級者は同じ技能スキルを共有するグループのカテゴリーを構成しているといえるが、初級者はその技能スキルが多種多様存在していることから、初級者という同じ技能スキルを持つカテゴリーは存在しないことがわかる。

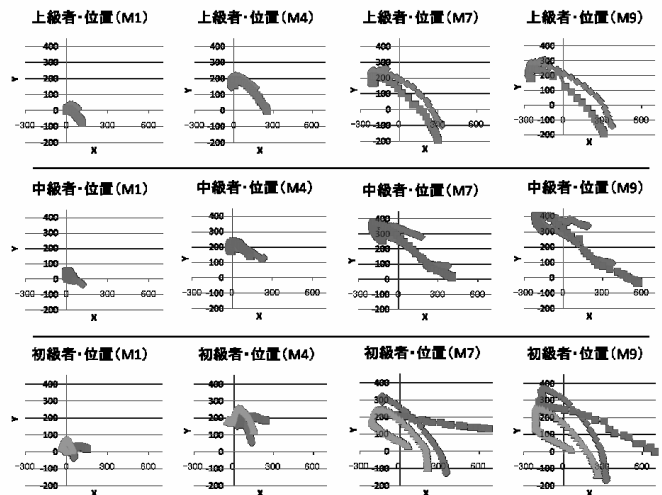


Fig. 4: Position of Markings

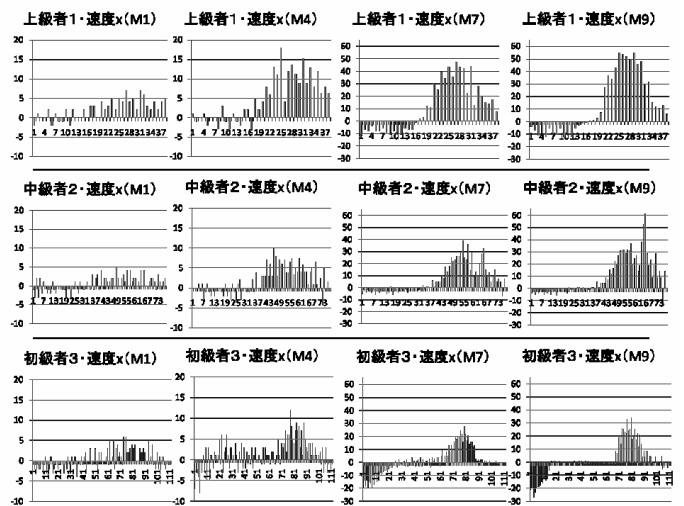


Fig. 5: Speed of Markings

### 3. TAM ネットワークによる内部モデルの同定

TAM ネットワークは共振学習とビジランス機能を持ち、パターン認識において有効な数理モデルである。構造的には、入力層の特徴マップ層、基盤層、カテゴリー層、クラス層の4層の階層構造からなる。与えられた教師値と出力値に差がある場合、特徴マップ層から基盤層への興奮性学習のボトムアップ学習およびクラス層から

基盤層への抑制性学習によるトップダウン学習とビジランス機能, カテゴリー層でのノード増加による特徴マップ層の特徴量抽出によって, 高い学習機能を確保することができる. 図 6 に TAM ネットワークの構成を示す.

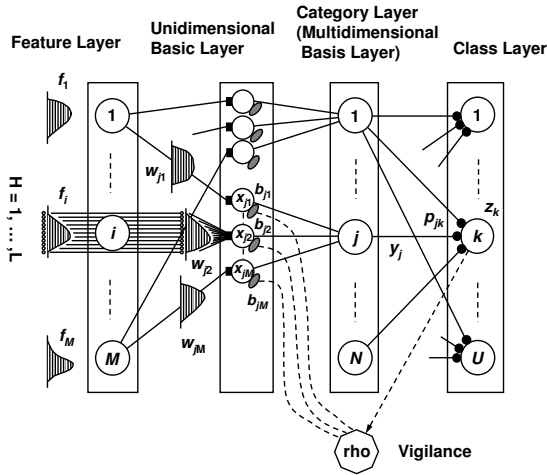


Fig. 6: TAM Network

基盤層とカテゴリー層では, 特徴マップ層の特徴マップ  $f_{ih}$  と学習荷重  $w_{jih}$  との活性値  $x_{ji}$  を計算して, クラス層への入力  $y_j$  を得る.

$$y_j = \prod_{i=1}^M x_{ji} = \prod_{i=1}^M \frac{\sum_{h=1}^L f_{ih} w_{jih}}{1 + \rho^2 b_{ji}} \quad (1)$$

ただし,  $\rho$  はカテゴリー層のノード数を決定するためのクラス層から基盤層へのトップダウン信号用のパラメータであり, ビジランスパラメータと呼ぶ. また,  $b_{ji}$  は抑制荷重である.

クラス層での出力値  $K$  は次式より計算される.

$$K = \{k | \max_k z_k\} = \{k | \max_k \sum_{j=1}^N y_j p_{jk}\} \quad (2)$$

ただし,  $p_{jk}$  は学習荷重である.

TAM ネットワークは, カテゴリー層においてノードの増幅機能をもつ. いま,  $K^*$  をクラス層での正しい教師値とし,  $OC$  を教師値の認識のためのしきい値とする.  $K \neq K^*$  の場合には, ビジランスパラメータ  $\rho$  は初期値  $\rho^{(init)}$  から  $z_{K^*}/z_K \geq OC$  の条件が満足されるか最大値  $\rho^{(max)}$  になるまで  $\rho^{(step)}$  ごとに上昇し, 最大値になった場合には, カテゴリー層のノードが 1 個分増加する. 一方,  $z_{K^*}/z_K \geq OC$  を満足する場合には, 学習モードに入り, 学習荷重  $w_{jih}$ ,  $p_{jk}$ ,  $b_{ji}$  を更新する.

ここでは, TAM ネットワークを用いて, 被験者の内部モデルを同定した. 本実験での卓球の技能スキルは, 観測マーキングの位置座標よりも位置の軌道に依存する. そこで, TAM ネットワークに被験者のフォアハンドストロークの観測データを適用するため, 9 名の被験者の静止画像のフレームの位置座標からなる観測データの各データタプルに対して, 当該データタプルの

フレーム先から 6 フレーム先までの 5 フレーム分のデータを同一タプルで重複させて観測データを時系列データとして再構成した. なお, 表象行動の技能評価は, 上級者, 中級者, 初級者の 3 クラスとした. 各観測マーキングの位置は  $(x, y)$  の 2 次元座標で表現されているので, 再構成後の観測データは 90 入力, 3 クラス出力からなる.

TAM ネットワークのロバスト性を検討するため, 上級者 2 名, 中級者 2 名, 初級者 3 名を学習用データ ( $TRD$ ) として, また, 上級者 1 名, 初級者 1 名を評価用データ ( $CHD$ ) として分割した. ただし, 学習用データあるいは評価用データとしてどの被験者を用いるかによって, 同定結果が大きく異なる可能性がある. そこで, 各観測マーキングでの位置座標の相関係数を計算し, 初級者 4 名のうち相関係数の高い 2 名を学習用データと評価用データに分割した 1 種類の観測データ (データ集合  $A$ ), 及び, 相関係数の高い 2 名を学習用データに分類した 2 種類の観測データ (データ集合  $B$  とデータ集合  $C$ ), 合計 3 種類の観測データを構成した. なお, 上級者間では, 相関係数の高い 2 名を学習用データとし, 残りの 1 名を評価用データとした.

Table 2: Recognition Rate of Data Sets

	認識率 (%)		
	学習用データ	評価用データ	平均
データ集合 $A$	53.7	57.5	55.6
データ集合 $B$	56.9	43.3	50.2
データ集合 $C$	55.2	42.3	48.8

TAM ネットワークの結果を表 2 に示す. どのデータ集合においても, 学習用データと評価用データの認識率はそう高くない. この原因は, 各クラスの観測データの個数に大きな差があるからと考えられる. そこで, 最も平均認識率が良かったデータ集合  $A$  に対して, データ個数が少ない上級者の観測データを当該フレームの次フレーム先から 5 フレーム分とし, 観測データを同一タプル内でさらに重複させて, 観測データの個数を増加した. 結果を表 3 に示す. なお, TAM( $A$ ) はデータ集合  $A$  に対する認識率であり, TAM( $A+$ ) はクラス間のデータ補正を行ったデータ集合  $A$  に対する認識率を示す. また, データマイニング手法である C4.5, Native Bayes Tree(NBT), Random Forest(RF) を用いて解析した結果も同時に示す. ただし, データマイニング手法の結果はデータ集合  $A$  に対する認識率である. また, 評価用データ ( $CHD$ ) において, 各手法によるクラスの認識個数を表 4 に示す.

これらの結果から, クラス間補正を行ったデータ集合  $A+$  に対する TAM ネットワークの認識率は補正前よりも向上していることがわかる. 一方, NBT と RF の学習用データに対する認識率は 100% と得られ, 学習データに対する過学習と考えられる. 評価用データに対する認識率は極めて悪い. C4.5 は学習用データと評価用データに対して良い結果を示した. クラス間補正後の TAM ネットワークの認識率は, 学習用データに対しては C4.5

Table 3: Recognition Rate of Modified Data Sets

	認識率 (%)		
	学習用データ	評価用データ	平均
TAM(A+)	61.2	43.0	52.1
TAM(A)	53.7	57.5	55.6
C4.5	98.1	43.3	70.7
NBT	100.0	32.8	66.4
RF	100.0	25.4	62.7

Table 4: Discrimination of Classes

	出力クラス	評価用データのクラス (個数)		
		上級者	中級者	初級者
TAM(A+)	上級者	5.8	0	5.8
	中級者	0	0	0
	初級者	48.2	0	34.2
TAM(A)	上級者	0.1	0	0
	中級者	0.3	0	1.0
	初級者	26.6	0	39.0
C4.5	上級者	14	0	2
	中級者	2	0	23
	初級者	11	0	15
NBT	上級者	1	0	2
	中級者	14	0	17
	初級者	12	0	21
RF	上級者	6	0	4
	中級者	13	0	25
	初級者	8	0	11

に及ばないものの、評価用データでは同程度の結果を示した。

一方、表 4 での各手法によるクラスの認識個数の結果から、NBT と RF は、評価データの上級者を中級者と認識し、初級者も中級者と認識する割合が高く、上級者と初級者からなる評価データに対して、それらの中間技能的レベルである中級者と誤認識する傾向がある。C4.5 は、評価データの上級者を初級者と認識しており、初級者も中級者と認識している。やはり、中間技能レベルの中級者として認識する傾向が見られる。TAM ネットワークは、上級者を初級者と見なしている。クラス間補正を行った後の TAM ネットワークの認識率がやや上級者側に改善していることがわかる。

次に、TAM ネットワークを用いて、観測マーキングとしての変数の感度分析を行った。まず、9 点の観測マーキングの 18 入力 (時系列データでは 90 入力) と 3 クラスの 1 出力の学習用データ (A+) を用いて、TAM ネットワークの認識率から第一優先度の最重要の観測マーキングを決定した。具体的には、18 入力変数 (90 入力変数) から一時的に任意に 1 つの観測マーキングの 2 入力変数 (10 入力変数) を取り除き、TAM ネットワークでの最も低い認識率となる入力変数を求めた。認識率が最も低くなる入力変数はその入力変数を取り除くことによって

Table 5: Sensitivity of Input Variables

入力変数の個数	削除入力変数・認識率 (%)				選択入力変数
	M1, M2	M3, M4	M5, M6	M7 ~ M9	
18					
12 ~ 14	42.9	57.4	51.1	48.2	M1, M2
8 ~ 10		45.9	48.4	41.6	M7 ~ M9
4		42.9	42.0		M5, M6 M3, M4

認識率が最も低下するので、その入力変数は優先度が最も高い入力変数であることを表している。ただし、ここでは、削除する入力変数の個数が多く煩雑になるので、9 点の観測マーキングの中で同位置にある (M1, M2), (M3, M4), (M5, M6), (M7 ~ M9) を組として、これらの組の変数削除を行った。

感度分析の結果を表 5 に表す。一時的に削除する入力変数として M1 と M2 を除去した場合、14(70) 出力の観測データに対する TAM ネットワークの認識率は 42.9% となり、最低の認識率となった。したがって、第 1 優先度の入力変数は M1 と M2 となった。同様に、次々と優先度入力変数を求め、結果として、M1, M2 → M7, M8, M9 → M5, M6 → M3, M4 の変数の順序で入力変数組の重要度が得られた。なお、M1, M2 及び M7, M8, M9 では、優先度入力変数が得られるに伴い認識率が低下していることがわかる。一方、M5, M6 と M3, M4 を削除した場合の認識率は高くなる。これらの結果から、上級者、中級者、初級者を判別するための重要な観測マーキングとしては、(1) 肩鎖関節点、(2) 肩峰点、及び (7,8,9) ラケット端点であり、肩とラケットの動作軌跡から上級者、中級者、初級者の違いを見分けることができるといえる。この結果は、第 2 章の図 4 と図 5 における解析結論と一致している。一方、(3) 橈骨点、(4) 尺骨点、(5) 橈骨茎状突起最下端点、(6) 尺骨茎状突起最下端点の各観測マーキングでは、上級者、中級者、初級者を判別する優先度入力変数とはならず、これらの観測マーキングだけでは、上級者、中級者、初級者の違いを判別することは難しいことを示している。

いま、優先度入力変数の重要性を表すため、第  $i$  番目の優先度入力変数で得られた認識率を  $R_i$  と表し、入力変数の重要度を次の  $P_i$  で定義する。

$$P_i = \frac{R_i - R_{i-1}}{\sum_i |R_i - R_{i-1}|} \quad (3)$$

$P_i$  の値は優先度入力変数の認識率の偏差の割合を表しているので、 $P_i$  が正の場合はクラス間を判別する際の重要度を示し、負の場合はクラス間の類似の重要度を示す。表 5 の結果では、 $P_{M1, M2} = 0.88$ ,  $P_{M7 \sim M9} = 0.06$ ,  $P_{M5, M6} = -0.02$ ,  $P_{M3, M4} = -0.04$  が得られた。図 7 に各観測マーキングの  $P_i$  を図示する。

最後に、TAM ネットワークから技能スキルのルールを獲得した。TAM ネットワークは 4 層の階層構造からなる。下位層の特徴マップ層と基盤層は観測データの入力特性を表現し、上位層のカテゴリー層とクラス層は入力特性の上位概念を表現する。カテゴリーノードは観測

データのデータ分布に依存して個数を増加させる。したがって、TAM ネットワークのカテゴリーノードに付帯する学習荷重  $w_{jih}$  と  $p_{jk}$  を解析することによって、与えられた観測データの入力特性とその上位概念を獲得することができる。

ここでは、クラス間補正を行ったデータ集合 ( $A+$ ) に対して、上級者、中級者、初級者の各クラスノードでの  $p_{jk}$  が最大値となる第  $J$  番目のカテゴリーノードを選出し、その第  $J$  番目のカテゴリーノードの  $w_{ji}$  を入力変数ごとに算出して、技能スキルの単機能技能とメタ技能を獲得した。

$$w_{ji} = \frac{\sum_{h=1}^L w_{jih}}{L}, \text{ for } \forall i \quad (4)$$

$$J = \{j | \max_j p_{jk}, k = 1, 2, 3\} \quad (5)$$

結果を図 8 に示す。上級者と初級者に対して、メタ技能のルールが獲得されている。

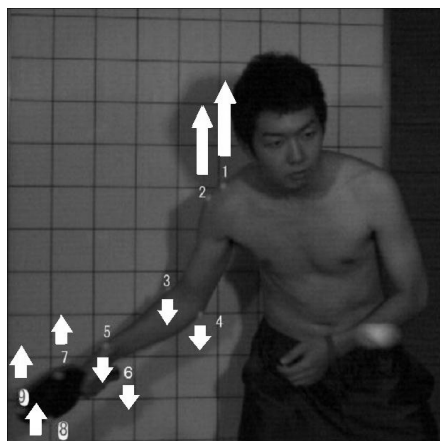


Fig. 7: Priority of Markings

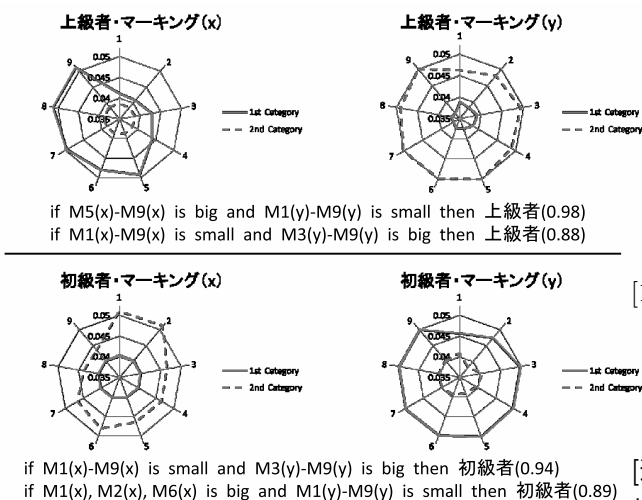


Fig. 8: Rule of Technique Skill

## 5. おわりに

本論文では、卓球のフォアハンドストロークの熟練性を3段階で評価して、TAM ネットワークを用いて、技能スキルの内部モデルを同定し、熟練性を向上させるための単機能技能とメタ技能について議論した。なお、本研究の遂行には、阪南大学 卓球部員、阪南大学 経営情報学部学生、及び、関西大学 総合情報学部 原 正直君の協力を得た。ここに感謝申し上げる次第である。

## 参考文献

- [1] 塩瀬 隆之, 榎木 哲夫, 川上 浩司, 片井 修: 生態心理学的アプローチからみた技能継承の技術化スキーム, 生態心理学研究, Vol.1, No.1, pp.11-18 (2004)
- [2] 松本 雄一: 組織と技能 技能伝承の組織論, 白桃書房 (2003)
- [3] 清水 鉄也, 望月 義幸, 姫野 龍太郎: 効率よいスイング動作の秘訣について, 理研シンポジウム「生体力学シミュレーション研究」, pp.175-183 (2003)
- [4] 望月 義幸, 姫野 龍太郎, 大村 皓一: スポーツにおける人工技能と新運動原理, システム/制御/情報, Vol.46, No.8, pp.498-505 (2002)
- [5] 葛西 順一, 森 武吉村 正, 太田 章: DTL法を用いた3次元解析による卓球のフォアハンド打法の研究, 早稲田大学人間科学研究, Vol.7, No.1, pp.119-127 (1994)
- [6] 宮木 操, 芦田 信之, 高島 規郎, 東 照正, 鶴田 宏次: 卓球競技におけるフォアハンドストロークの動作分析 -スイングのタメについて-, 日本体育学会第42回大会, pp.681 (1991)
- [7] Jürgen Perl, Arnold Baca: Application of Neural Networks to Analyze Performance in Sports, *Proceedings of the 8th Annual Congress of the European College of Sport Science*, in Salzburg (2003).
- [8] 林 勲, J.R.Williamson: TAM Network のブルーニング手法の提案, システム制御情報学会論文誌, Vol.17, No.2, pp.81-88 (2004)
- [9] 岡 秀郎, 生田 章, 西羅 彰夫: 卓球におけるフォアハンド技術の筋電図的研究, 兵庫教育大学研究紀要, Vol.20, pp.19-27 (2000)
- [10] 森部 淳, 阿江 通良, 藤井 範久, 法元 康二, 湯田 淳: 卓球競技におけるフォアハンドアタックに関する研究 -配球の変化に対する対応動作に着目して-, 日本体育学会第54回大会, pp.377 (2003)

## [連絡先]

林 勲 関西大学 総合情報学部  
〒569-1095 大阪府高槻市霊仙寺町 2-1-1  
tel. 072-690-2448  
e.mail ihaya@kcn.res.kutc.kansai-u.ac.jp