

# TAMネットワークによる卓球技能評価の検討

## A Consideration on Table Tennis Technique Evaluation Using Motion Analysis Model by TAM Network

林 勲<sup>1\*</sup> 前田 利之<sup>2</sup> 藤井 政則<sup>2</sup> 王 碩玉<sup>3</sup> 田阪 登紀夫<sup>4</sup>

Isao Hayashi<sup>1</sup> Toshiyuki Maeda<sup>2</sup> Masanori Fujii<sup>2</sup> Shuoyu Wang<sup>3</sup> Tokio Tasaka<sup>4</sup>

<sup>1</sup> 関西大学 <sup>2</sup> 阪南大学 <sup>3</sup> 高知工科大学 <sup>4</sup> 同志社大学

<sup>1</sup> Kansai Univ. <sup>2</sup> Hannan Univ. <sup>3</sup> Kochi Univ. of Technology <sup>4</sup> Doshisha Univ.

**Abstract:** In this paper, we discuss table tennis technique evaluation using motion analysis model by TAM networks and data mining methods. For students of university, we recorded the continuous forehand stroke of 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 embodied knowledge classified member of table tennis club, middle level palyer 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

人間の網膜での動作の視覚情報は受容野に対応した神経節細胞で処理され、外側膝状体を介して、第一視覚野で対象画像の方位選択性が検知される。対象の知覚はより上位の視覚前野以降で認識される [1]。この初期視覚の処理過程は、Hubel-Wieselの階層仮説に代表され、多くの有用な視覚系モデルが提案されている [2-5]。特に、Williamson が提案した TAM (Topographic Attentive Mapping) ネットワーク [5,6] は有用である。TAM ネットワークは、入力層、基盤層、カテゴリー層、出力層の4層構造からなる。入力層は受容野を想定し方位選択成分を検出するため、属性データを分布データとして取り扱う。基盤層は外側膝状体に対応し、視覚野への中継機能と興奮性・抑制性学習を構造化している。カテゴリー層では抑制性ノードを構成しており、学習された受容野の方位選択性分を全結合している。出力層は第一視覚野あるいは側頭葉を構造化し、教師信号を与える。与えられた教師値と出力値に差がある場合、基盤層での興奮性学習、出力層から基盤層へのフィードバック信号とビジランスパラメータによる抑制性学習、およびカテゴリー層ノードの増設によるパターンモデルの生成など、パターン問題に対する精度の高い学習が可能である。林らは、この TAM ネットワークからのファジィルールの獲得法 [6] を提案し、網膜構造の受容野の導入方法 [7] についても議論している。

一方、動作における技能スキルは単機能成果を生成する単機能技能と環境変化に適應するメタ技能との階層構造から構成されていると言われている [8,9]。技能スキルの階層的な技能構造は身体知の内部モデルとして構成され、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 [9]。技能者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や表象行動への表現ボトムアップ処理、及び、表象行動からメタ技能、単機能技能への調整トップダウン処理が相互に機能して、身体知の内部モデルを高精度化し熟練性が達成される。また、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 [10-14] が推進されている。望月ら [12] は「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 [13] 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。

本論文では、卓球のフォアハンドストローク [13,14] 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、TAM ネットワークにより身体知としての内部モデルを同定する。具体的には、まず、被験者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

\*連絡先：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  
E-mail: ihaya@kcn.res.kutc.kansai-u.ac.jp

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、TAM ネットワークと C4.5, Native Bayes Tree, Random Forest を用いて、身体知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、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ケティングの重要度とファジイルールの技能スキル (身体知) として獲得した。

## 2 TAM ネットワーク

TAM ネットワークは J.R. Williamson [5] によって提案された視覚系ニューラルネットワークである。その後、林らによって、ネットワーク構造の簡素化とネットワークからのルール獲得 [6]、網膜構造の受容野の導入 [7] などの改良が行われている。構造を図 1 に示す。下位層から上位層に向かって、入力層、基盤層、カテゴリー層、出力層の 4 層からなる。

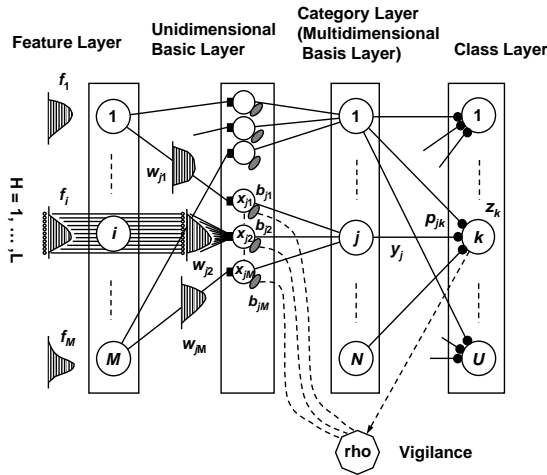


図 1: TAM Network

入力層は網膜細胞の受容野を想定しており、入力信号を分布データとして受信する。いま、与えられたデータ集合  $D$  が  $M$  個の入力属性と 1 個の出力属性からなる  $R$  個のデータとする。第  $i$  番目の入力属性における第  $s$  番目のデータを  $f_{si}$ ,  $s = 1, 2, \dots, R$  で表し、その出力値を  $k$  とする。まず、 $f_{si}$  をその大きさにより順位づけし、 $1, 2, \dots, s, \dots, R$  とする。次に、ランク法を用いて各属性ごとに正規化する。

$$I_{si} = \frac{s - 0.5}{R}, \quad i = 1, 2, \dots, M \quad (1)$$

入力層では、この  $I_{si}$  を用いて受容野での信号入力を分布データ  $f_{sih}$  として受信する。

$$f_{sih} = \frac{\exp[-0.5(LI_{si} - h + 0.5)^2]}{\sum_{h'=1}^L \exp[-0.5(LI_{si} - h' + 0.5)^2]} \quad (2)$$

ただし、 $h$  は分布の離散量  $h = 1, 2, \dots, L$  を表す。なお、入力層への入力信号はデータ集合  $D$  から 1 個ずつ逐次に入力されるので、以後、簡素化のため、入力  $f_{sih}$  を  $f_{ih}$  として表記する。

基盤層とカテゴリー層は神経節細胞もしくは外側膝状体に対応し、視覚野への中継機能と興奮性、抑制性学習を構造化している。基盤層では、シナプス荷重  $w_{jih}$  により  $j$  番目のノードでの活性値  $x_{ji}$  を計算し、第 1 視覚野の出力層から選択的注意のフィードバック信号を受ける。また、カテゴリー層では、基盤層の信号を統合し、出力層への出力  $y_j$  を計算する。

$$x_{ji} = \frac{\sum_{h=1}^L f_{ih} w_{jih}}{1 + \rho^2 b_{ji}} \quad (3)$$

$$y_j = \prod_{i=1}^M x_{ji} \quad (4)$$

ただし、 $b_{ji}$  は抑制のためのシナプス荷重であり、 $\rho$  はフィードバック信号を表すビジランスパラメータである。後述の学習モードにおいて、 $w_{jih}$  は入力  $f_{ih}$  に近似するように学習されるので、カテゴリー層の各ノードは入力層の各入力パターンを記憶した構造となる。

出力層は第 1 視覚野を構造化している。 $k$  番目の出力ノードでは、 $j$  番目のカテゴリーノードとのシナプス荷重  $p_{jk}$  を介して出力値  $z_k$  を計算する。最大値を有するノード番号  $K$  が TAM ネットワークの出力値として出力される。

$$z_k = \sum_{j=1}^N y_j p_{jk} \quad (5)$$

$$K = \{k | \max_k z_k\} \quad (6)$$

いま、 $K^*$  を正しい教師値としよう。TAM ネットワークの出力値  $K$  が  $K^*$  と一致しない場合には、ビジランスパラメータ  $\rho$  を初期値  $\rho = 0$  から  $\rho^{(step)}$  分だけ上昇させ、 $b_{ji}$  とともにカテゴリー層のノードの活性値  $x_{ji}$  を抑制し、相対的に他のノードの活性値を上昇させる。これは網膜に投影された対象への注意をより強調させる第 1 視覚野から外側膝状体への“選択的注意”の発動機能を想定している。

$\rho$  は  $z_{K^*}/z_K \geq OC$  の条件が満足されるか最大値  $\rho^{(max)}$  になるまで上昇を続ける。ただし、 $OC$  は評価のしきい値であり、 $0 \leq OC \leq 1$  である。ビジランスパラメータ  $\rho$  が最大値  $\rho^{(max)}$  を越えた場合には、現在のカテゴリー層のノード構成では  $K^*$  を十分に表現で

きないと考え、カテゴリー層のノードを新たに1個分増加させる。

$$\begin{aligned} & \text{If } z_{K^*}/z_K < OC \text{ then repeat} \\ & (a) \quad \rho = \rho + \rho^{(step)} \\ & (b) \quad \text{equation (3) - (6)} \\ & \text{until either } z_{K^*}/z_K \geq OC \text{ or } \rho \geq \rho^{(max)} \end{aligned} \quad (7)$$

一方、 $z_{K^*}/z_K \geq OC$  を満足する場合には、現在のネットワーク構造で  $K^*$  を正しく表現していると考え、出力値  $K$  をより  $K^*$  に近似させるため、学習モードに入る。

学習モードでは、まず出力層からカテゴリー層へのフィードバック信号  $y_j^*$  を計算する。

$$z_k^* = \begin{cases} 1 & ; \text{ if } k = K^* \\ 0 & ; \text{ otherwise} \end{cases} \quad (8)$$

$$y_j^* = \frac{\prod_{i=1}^M x_{ji} \times \sum_{k=1}^U z_k^* p_{jk}}{\sum_{j'=1}^N \prod_{i=1}^M x_{j'i} \times \sum_{k=1}^U z_k^* p_{j'k}} \quad (9)$$

シナプス荷重  $b_{ji}$ ,  $p_{jk}$ ,  $w_{jih}$  は次式により更新される。

$$\Delta b_{ji} = b_j^{(rate)} y_j^* (x_{ji} - b_{ji}) \quad (10)$$

$$\begin{aligned} \Delta p_{jk} &= p_j^{(rate)} y_j^* (z_k^* - p_{jk}) \\ &= \frac{\alpha y_j^* (z_k^* - p_{jk})}{\alpha + n_j} \end{aligned} \quad (11)$$

$$\begin{aligned} \Delta w_{jih} &= w_j^{(rate)} y_j^* (f_{ih} - w_{jih}) \\ &= \frac{\alpha y_j^* (f_{ih} - w_{jih})}{\alpha \beta(M) + n_j} \end{aligned} \quad (12)$$

ただし、

$$\beta(M) = \frac{\lambda^{1/M}}{1 - \lambda^{1/M}}, \quad \lambda \in (0, 1) \quad (13)$$

$$\Delta n_j = \alpha y_j^* (1 - n_j) \quad (14)$$

であり、 $\alpha$  と  $\lambda$  は係数である。なお、 $b_j^{(rate)}$ ,  $p_j^{(rate)}$ ,  $w_j^{(rate)}$  は学習係数であり、 $b_j^{(rate)}$  は定数、 $p_j^{(rate)}$  はシミュレティッドアニーリング法の補正值、 $w_j^{(rate)}$  はさらに入力次元  $M$  による補正項  $\beta(M)$  を加えた係数である。

学習モードでは、フィードバック信号  $y_j^*$  を介して、 $w_{jih}$  は  $f_{ih}$  に近似するように学習される。また、 $p_{jk}$  は  $z_k^*$  に近似するように学習され、 $b_{ji}$  は  $x_{ji}$  に近似するように学習される。これらの学習は Grossberg の winner 学習を用いており、共振学習 [15] という。

なお、学習は TAM ネットワークに入力データ  $f_{ih}$  を逐次的に投入するごとに行い、全学習データはデータ集合  $D$  を1エポックとして数エポック回数分とする。

### 3 卓球のフォアハンドストロークの分析

本研究では、筋電図検査やマーキング観測法等による身体的構造や骨格構造を用いるのではなく、内部モデルとして TAM ネットワークを用いて、被験者の動作軌跡の観測データと表象行動の技能評価から卓球技能の身体知を獲得する。本システムの構造を図2に示す。

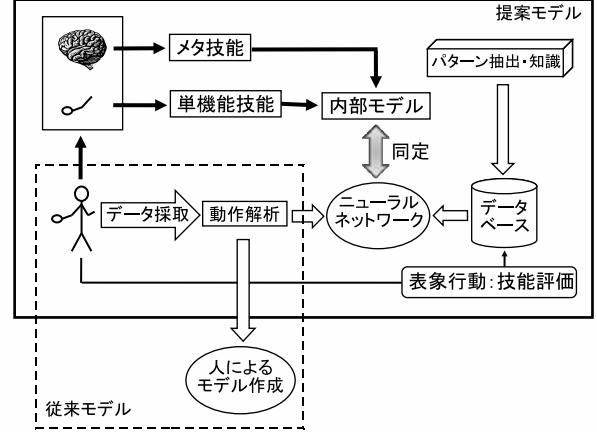


図2: Proposed System

実験試技では、表象の技能評価として、卓球部に所属する大学生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大学生3名を中級者、全くの卓球競技の経験がない大学生5名を初級者として分類した。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)橈骨茎状突起最下端点,(6)尺骨茎状突起最下端点,(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3参照)。

被験者の対角線延長上に配球マシン(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。被験者は配球ボールを相手コートのフォアクロスに返球し、フレームレート90fpsの高速度カメラでフォアハンドストロークの動作軌跡を撮影する。撮影された連続画像から、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、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。上級者、中級者、初級者の観測マーキングの2次元座標の図4と水平方向( $x$ )での




図 3: Measurement Markings

速度の図 5 から、次の結論が得られた。

- 上級者では、 $M1 \sim M9$  の位置の座標が極めて一致 (相関係数:  $x = 0.985, y = 0.790$ ) し、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。  
上級者の速度から、全観測マーキングでボールインパクトの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。すなわち、インパクトで最大速度を出す身体知を習得していると言える。
- 中級者では、 $M1 \sim M9$  の位置の座標は異なる個所も見られた (相関係数:  $x = 0.919, y = 0.607$ )。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。  
中級者の速度から、インパクトでの速度が最大となっているが、 $M7$  と  $M9$  の速度分布は双峰形となっており、ボールにあてるためラケットの速度を微調整していることがわかる。
- 初級者では、 $M1 \sim M9$  の位置座標は異なる形状を示した (相関係数:  $x = 0.073, y = -0.04$ )。特に、 $M1$  での位置座標は軌跡の範囲が大きく、上級者や中級者に比べて、肩が動いている。また、 $M7$  と  $M9$  での位置座標は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、 $M3 \sim M9$  において、インパクトの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「ラケットでボールを迎えに行く動作」が見られた。また、 $M7$  と  $M9$  の速度がゼロの時間帯に、 $M1$  において全時間帯で速度が検出され肩が動くことから、ラケットの移動に対して肩や肘が動く「体が開く動作」が見られた。

- 上級者は、ラケットを水平方向に幅を小さくコンパクトに振り (幅:  $M1 = 117, M4 = 283, M9 = 639$ )、インパクトの瞬間だけ速度を最大にする身体知を習得している。初級者は、水平方向の幅が大きいにも関わらず (幅:  $M1 = 185, M4 = 289, M9 = 911$ )、インパクト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。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様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。

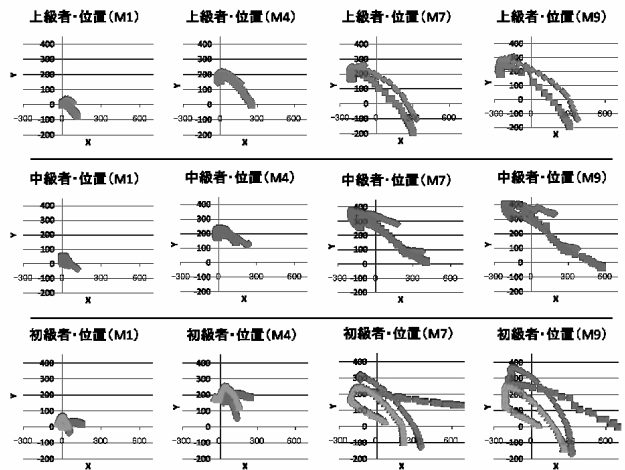


図 4: Position of Markings

## 4 TAM ネットワークによる内部モデルの同定

TAM ネットワークを用いて、被験者の技能スキルを同定した。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2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構成した。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  $x - y$  2次元座標で表現されているので、構成後の観測データは90入力、3クラス出力からなる。

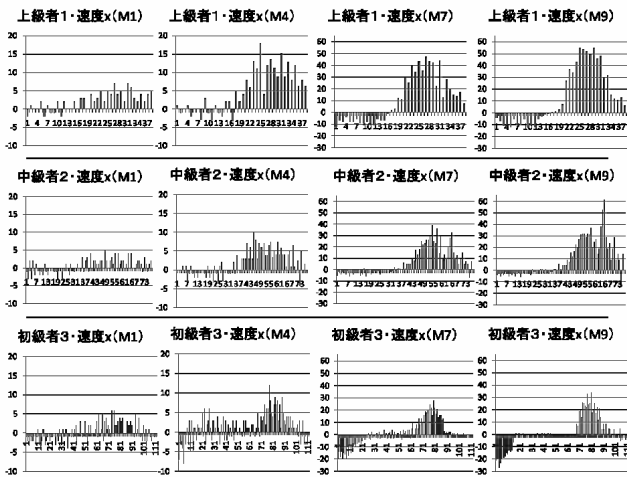


図 5: Speed of Markings

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、データ集合にデータ数の偏りがあるため、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 1 に示す。なお、TAM(D) はデータ集合 D に対する認識率であり、TAM(D+) はクラス間のデータ補正を行ったデータ集合 D 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 D に対する認識率である。

表 1: 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

これらの結果から、クラス間補正を行ったデータ集合 D+ 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。しかし、学習用データと評価用データの認識率はそう高くない。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 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。

次に、学習用データ (D+) を用いて、TAM ネットワークにより観測マーキングの感度分析を行った。学習用データの 18 入力変数 (90 入力変数) から一時的に任意に 2 つの観測マーキングの 2 入力変数 (10 入力変数) を取り除く。認識率が最も低くなる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。

表 2: 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

感度分析の結果を表 2 に表す。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。M1, M2 及び M7, M8, M9 の削除では、認識率が低下するが、M5, M6 と M3, M4 では、認識率は高くなる。したがって、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、図 4 と図 5 における解析結論と一致している。

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  $P_i = (R_i - R_{i-1}) / (\sum_i |R_i - R_{i-1}|)$  で定義した。表 2 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。

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 ネットワークのカテゴリ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。カテゴリ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 (D+) 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  $J$  番目のカテゴリノードを選出し、その第  $J$  番目のカテゴリノードの  $w_{Ji}$  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。

$$w_{Ji} = \frac{\sum_{h=1}^L w_{Jih}}{L}, \text{ for } \forall i \quad (15)$$

$$J = \{j | \max_j p_{jk}, k = 1, 2, 3\} \quad (16)$$

結果を図 6 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。

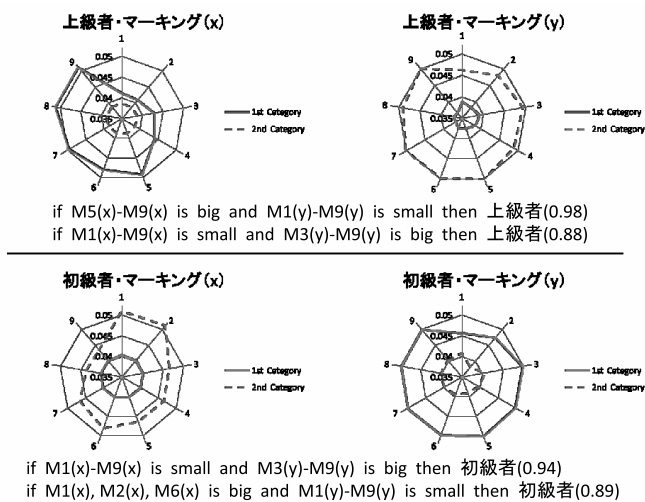


図 6: Rule of Technique Skill

## 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。

## 参考文献

- [1] 松田 隆夫: 知覚心理学の基礎, 培風館 (2000)
- [2] S.Grossberg: How does the cerebral cortex work? Learning, attention, and grouping by the laminar circuits of visual cortex, *Spatial Vision*, Vol. 12, No. 2, pp. 163–185 (1999).
- [3] H.Neumann and W.Sepp: Recurrent V1-V2 interaction in early visual boundary processing, *Biological Cybernetics*, Vol. 81, pp. 425–444 (1999).
- [4] K.Fukushima: Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, Vol. 36, pp. 193–202 (1980).
- [5] J.R.Williamson: Self-organization of topographic mixture networks using attentional feedback, *Neural Computation*, Vol. 13, pp. 563–593 (2001)
- [6] 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)
- [7] 林 勲, ジェームズ R. ウィリアムソン: ガボール型受容野をもつ TAM ネットワークの提案, 知能と情報, Vol. 18, No. 3, pp. 434–442 (2006)
- [8] 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)
- [9] 松本 雄一: 組織と技能 技能伝承の組織論, 白桃書房 (2003)
- [10] 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)
- [11] 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)
- [12] 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)
- [13] 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)
- [14] 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)
- [15] G.A.Carpenter, S.Grossberg and J.Reynolds: ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network, *Neural Networks*, Vol. 4, pp. 565–588 (1991).