

# スウィングのばらつきを考慮したゴルフクラブの最適設計

86690 王 春暁  
指導教員 鈴木克幸 教授

The purpose of this study is to provide an optimal designed golf club to the golf beginners. High quality data is necessary to study the optimum design of the golf club. Therefore, the trial participants are all excellent golf players to ensure the high quality of the measurement data. The optimum design of the golf club can not be done for golf beginners, because they can not provide high quality test results. Taking into this account, it is expected this study could find out the swing pattern from the professionals and could supply an optimal designed golf club for the golf beginners.

Key Words: Golf Swing, Pattern recognition, cluster analysis, Optimal Design

## 1. 緒言

### 1.1 先行研究

先行研究の試みとしては、グリップの動きを3次元計測し、その計測結果に基づきゴルフクラブの運動の解析を行った。また、ゴルフクラブの曲げ剛性、ねじり剛性、ヘッド重量などの特性の変化によるスイングの変化の影響を考慮するために、実験計画法に基づき試作したクラブに対してプロゴルファーによるスイング計測を行い、その計測データを多項式による応答曲面で補間した。さらに、人体モデルを作成し、クラブおよび人体の動作について、クラブ特性の変化に対する応答曲面を作成した。

次に、作成した応答曲面を用いてヘッド速度の解析および身体負荷解析を行い、最終的に双方の評価を合わせた目的関数を設計し、最適化を行いヘッド速度が大きく且つ身体負荷が少ないシャフトを設計する。最後にヘッド速度と身体負荷についてのパレート解を作成した。

### 1.2 本研究の目的

ゴルフクラブの最適設計の研究は実験計画、応答曲面と最適化法を使うため、「計測データの質」が必要となる。今まで、計測データの「質」を保証できる上級者のゴルファーを限定して、計測を行った。スウィングのバラツキがある初心者や一般者を対象できない。スウィングのバラツキがあるゴルファーにも最適なクラブを設計するのは本研究の目標である。上級者のデータベースから、初級者のスウィングパターンと類似している上級者を見つけ出す。その上級者の最適設計されたクラブをスウィングが不安定な初級者に提案すると考えた。

本研究の目的は、統計学の「パターン認識」のなかで、いくつかの手法を用いて、上級者のデータベースから、バラツキがある一般者と類似している上級者を識別し、さらに、ゴルフスウィングに対して、識別能力が高い手法を判別することである。

### 1.3 パターン認識用パラメータ

スウィングの特徴はゴルファーによってそれぞれ違う。本研究はパターン認識を行う際に、どのようなパラメータを用いるかを重要なポイントである。飛距離向上のために、ヘッドと体の距離を短くして振る事によって速く腕を回せ、インパクトの寸前に腕を伸ばせば、最大スピードのインパ

クトが得られることになる。これを実現できるかできないかの違いが、プロと一般者の大きな差とも言われている。本研究は正しいスウィングを行うメカニズムを評価する、グリップ速度・シャフト軸周りの回転速度・ボディーターンの回転速度の三つの要素をパターン認識用パラメータとする。

## 2. スウィング計測実験

### 2.1 スウィング計測実験の目的

本実験の目的はパターン認識するために、スウィングデータから、各被験者のスウィングパターンを抽出する。

### 2.2 実験内容

#### 2.2.1 スウィング回数の決定法

「仮説検定」を用いて、スウィング回数を決定する。スウィング回数と仮説を棄却する境界値  $z$  の関係について、図1のように得られた。




図1 境界値  $z$  とスウィング回数の関係

スウィング回数が多いほど分散が小さくなるが、被験者の体力を考慮し、本研究の実験回数は6回と決めた。

#### 2.2.2 実験概要

##### (a) 被験者

スウィング計測実験の被験者としては、9人の上級者と1人の一般者合わせて10人である。被験者の特徴データは表1ようになる。

##### (b) 測定項目

この実験で測定する主要項目はクラブの並進位置と回転姿勢である。そのため、グリップにマーカーをつけ、カメラによる連続写真撮影によりマーカーの3次元軌跡を

計測する。

表 1 被験者の特徴データ

被験者	種別	年齢	身長(cm)	体格	handicap
A	一般者	30	170	M	20
B	上級者	38	185	LL	0
C	上級者	45	165	M	10
D	上級者	37	175	L	10
E	上級者	41	170	M	10
F	上級者	45	175	L	10
G	上級者	38	170	M	15
H	上級者	34	170	L	5
I	上級者	44	170	L	10
J	上級者	54	165	M	15

### (c) 実験の実施

各被験者につき用意した1本のクラブを6回ずつ計測を行う。高速カメラでは、図2のように60(コマ/秒)の速さで連続写真を撮影する。



図2 スイング連続写真の1コマ

## 2.3 計測データの処理

### 2.3.1 トップおよびインパクトの判定

これら計測データを用いてパターン認識するが、取得したデータそのままの場合、それぞれデータ取得開始から終了まで時間幅が変わる。また、開始からインパクトまでの時間もそれぞれ異なる。これらの要素を考慮しなければ正確なパターン認識ができない。ここで、計測データからトップからインパクトまでのスウィングデータを抽出する。

#### (a) トップの判定

バックスウィングし始めて、バックスウィングの頂点のことはトップと呼ぶ。その時はトップのタイミングとする。




図3 線形補間後のスウィングデータ

### (b) インパクトの判定

計測データから回転角度を算出し、z軸周りの回転角度は $3\pi/2$ の時、インパクトのタイミングとなる。しかし、連続写真の離散値を使っているため、ちょうどインパクトのタイミングが写っていない場合に、先行研究では、インパクト直前のタイミングはインパクトとした(図3黒線)。本研究は線形補間を行い、正しいインパクトのタイミングを計算する(図3の点線)。図3はトップとインパクトまでのスウィング軌道と示しており、インパクト際に、クラブはちょうど地面と垂直となる。

### 2.3.2 スウィングデータの正規化

トップからインパクトまでのスウィング時間がそれぞれ異なる(図4の左)。これらの要素を考慮しなければ、正確なパターン認識ができない。なお、T1、T2は、トップの時刻を0としたときのインパクトの時刻である。スウィング時間の長さを揃うには、時間軸をすべて0.01刻みで、0から1まで伸ばす正規化の処理を行った。1は揃えた後の共通のデータ終了時刻である(図4右)。




図4 揃える前(左)と後(右)のデータ

## 3. クラスタ解析

### 3.1 クラスタ分析の概要

クラスタ分析とは、二つ以上のデータがあるとき、類似度を手がかりにデータをいくつかのグループに分類させる方法である。クラスタ分析には階層的方法と非階層的方法の2つの計算方法がある。非階層的方法には、k-means法が代表的である。

ゴルフのスウィング特徴は百人百様といわれている。しかし、本研究はさまざまな特徴の中で、似ている特徴があるはずと考えている。似ている特徴を集め、部分集合となる。すべてのデータに対して、いくつかの部分集合を切り分けられる。本研究は、9人の上級者に対して、k-means(K平均法)法を用いて、似ている特徴同士を集め、いくつかの部分集合(クラスタ)に切り分ける。

### 3.2 k-means法

非階層型クラスタリングでk-means法はよく用いられる手法である。k-means法は、予め指定した数のクラスタにデータを分割し、そのクラスタ内部で中心をとり再度クラスタに分割しなおすという方法を繰り返す(図4)。




図5 k-means法のクラスタ分析

### 3.3 クラスタ数の決定法

本研究は、9人の上級者に対して、クラスタ解析を行うために、あらかじめいくつのクラスタ数にするかを決めておく必要がある。初期クラスタ数は二つ、三つ、四つのクラスタに切り分けた。そして、最適な初期クラスタ数を決定するために、本研究は、クラスタ数自動決定法を用いた。初期クラスタ数自動決定法は、Jain<sup>1)</sup>で紹介されている以下の数式(1, 2)を用いた。

$$e_j = \frac{1}{n_j} \sum_{i=1}^{n_j} D(F_i^{(j)}, \mu_j), m_{j,k} = D(\mu_j, \mu_k) \quad (1)$$

$F_i$ はクラスタ中の*i*番目のデータ、 $\mu$ は各クラスタの平均値である。

$$R_{j,k} = \frac{e_j + e_k}{m_{j,k}}, R_k = \max\{R_{j,k}\}, j \neq k \quad (2)$$

$$DB(K) = \frac{1}{K} \sum_{k=1}^K R_k, K > 1$$

一番小さい $DB(k)$ のクラスタ数は最適な初期クラスタ数である。結果として、

$$DB(2) = 0.83, DB(3) = 0.79, DB(4) = 3.4$$

三つのクラスタ数は最適である。そして、9人の上級者に対して、k-means法を用いてクラスタ解析を行う。クラスタ解析結果を用いて、パターン認識を行う。

### 3.4 クラスタ分析の結果

クラスタ数は3つだと3.3節でわかった。そして、9人の上級者に対して、クラスタ解析を行った。振り分けた結果は表2のようになった。

表2 k-means法で分析した結果

	上級者
Cluster1	C,I
Cluster2	B,D,E
Cluster3	F,G,H,J

振り分けた結果をクラスタごとにプロットしたのは図6, 7, 8である。同じクラスタに集まっているスウィングデータ同士はほぼ同じ形である。




図6 クラスタ 1




図7 クラスタ 2




図8 クラスタ 3

## 4. スウィングの識別

### 4.1 概要

確率モデルを用いて、スウィング識別を行う。ここで、注意したいのは9人の上級者に一人ずつ識別することではなく、識別するのは一般人のスウィングパターンとどのクラスタに類似しているかのことである。

### 4.2 分散が1の確率モデルによる識別法

クラスタ  $k(k=1, 2, 3)$  のデータ:

$$y(k) = \{y_{i,j}(k) | i=1, \dots, n, j=1, \dots, J\}$$

一般人1人のデータ(識別すべきデータ):

$$z = \{z_{i,j} | i=1, \dots, n, j=1, \dots, J\}$$

データ  $z$  に対する正規分布モデルは式(3)のようになる。

$$p(z|\theta) = (2\pi)^{-nJ/2} \exp\left(-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \theta_i)^2\right) \quad (3)$$

ここでは、 $\theta = \{\theta_i\}_{i=1}^n$  が未知パラメータである。スウィングデータを正規化処理したため、 $t$  は0.01刻みで0から1までなので、 $i=1, \dots, 100$ 。

最尤法:

未知パラメータを定めるため、最尤法を用いて、尤度関数  $P(y(k)|\theta)$  を最大化する  $\theta$  を求める。

$$\hat{\theta}(k) = \arg \max(P(y(k)|\theta)) \quad (4)$$

より、以下式4に書き換える

$$\frac{\partial}{\partial \theta} [(2\pi)^{-nJ/2} \exp(-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^J (y_{i,j} - \theta_i)^2)] = 0 \quad (5)$$

より、パラメータ  $\hat{\theta}(k) = \{\bar{y}_i(k)\}_{i=1}^n$  が得られる

識別ルール:

一般人の被験者のデータを各確率モデル式(3)に代入し、確率を計算する。一般人の被験者のスウィングパターンは確率が一番大きいクラスタに類似している。識別式としては、式6(a)を用いる。

$$k = \operatorname{argmax} (2\pi)^{-nJ/2} \exp(-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \bar{y}_i(k))^2) \quad (6a)$$

実際の計算では、式(6a)の形は扱いづらいので、両側を自然対数をとる(式6b)。

$$k \approx \operatorname{argmax} \ln((2\pi)^{-nJ/2} \exp(-\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \bar{y}_i(k))^2))$$

$$\approx \operatorname{argmin} \sum_{i=1}^n (\bar{z}_i - \bar{y}_i(k))^2, \quad \bar{z}_i = \frac{1}{J} \sum_{j=1}^J z_{i,j}$$

式(6b)はユークリッド距離の2乗と同じ形である。つまり、分散が1場合、識別式は二乗距離の最小化に相当する。

### 4.3 分散がクラスタごとに異なる確率モデル

データzに対する正規分布モデル:

$$p(z|\theta) = (2\pi\sigma^2)^{-nJ/2} \exp(-\frac{1}{2\sigma^2} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \mu_i)^2) \quad (7)$$

ここでは、 $\theta = (\mu_1, \dots, \mu_n, \sigma^2)$  が未知パラメータである。本研究では、分散は時刻に依存しないと扱っている。

最尤法を用いて  $p(y(k)|\theta)$  を最大化する  $\theta$  を求める。

$$\hat{\mu}_i(k) = \frac{1}{J} \sum_{j=1}^J y_{i,j}(k) \quad \hat{\sigma}^2(k) = \frac{1}{J} \sum_{j=1}^J (y_{i,j}(k) - \hat{\mu}_i(k))^2 \quad (8)$$

三つのクラスタに対して、三つの確率モデルの未知パラメータは最尤法を用いて得られる。

識別ルール:

一般者のデータを式(7)に代入し、確率を計算する。一般人の被験者スウィングパターンは確率が一番大きいクラスタに類似する。識別式は以下の式(9)になる。

$$k = \operatorname{argmax} ((2\pi\hat{\sigma}^2(k))^{-nJ/2} \exp(-\frac{1}{2\hat{\sigma}^2(k)} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \hat{\mu}_i(k))^2)) \quad (9)$$

$$\approx \operatorname{argmin} \left\{ \frac{nJ}{2} \ln(\hat{\sigma}^2(k)) + \frac{1}{2\hat{\sigma}^2(k)} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - \hat{\mu}_i(k))^2 \right\}$$

### 4.4 多項式回帰モデルによる識別法

データzに対する次数dの多項式:

$$z_{i,j} = t_i + \varepsilon_{i,j}, \quad \varepsilon_{i,j} \sim N(0, \sigma^2) \quad (10)$$

$$t_i = \beta_0 + \beta_1 i + \dots + \beta_d i^d$$

が得られる。パラメータ  $\theta = (\beta_0, \beta_1, \dots, \beta_d, \sigma^2)$  である。

多項式  $t_i = \beta_0 + \beta_1 i + \dots + \beta_d i^d$  は本質を分かりやすくいえば、4.3節の各時刻の平均値  $\mu_i$  を最小2乗法を用いて、曲線で表現するという考え方である。多項式の次数について、5次の多項式を使う。

・確率密度関数

$$p(z|\theta) = (2\pi\sigma^2)^{-nJ/2} \exp(-\frac{1}{2\sigma^2} \sum_{i=1}^n \sum_{j=1}^J (z_{i,j} - t_i)^2) \quad (11)$$

$$t_i = \beta_0 + \beta_1 i + \beta_2 i^2 + \beta_3 i^3 + \beta_4 i^4 + \beta_5 i^5$$

最尤法:

$$\hat{\beta}(k) = \operatorname{argmin} \frac{1}{nJ} \sum_{i=1}^n \sum_{j=1}^J (y_{i,j}(k) - \sum_{d=0}^5 \beta_d t^d)^2 \quad (12)$$

$$\hat{\sigma}^2(k) = \frac{1}{nJ} \sum_{i=1}^n \sum_{j=1}^J (y_{i,j}(k) - \hat{t}_i(k))^2$$

識別ルール:

識別式は4.3節の式(9)と同じで、 $\mu_i$ の代わりに  $t_i$  を使う。

### 4.5 異なるパターン認識法による識別結果の比較

一般者は以上の3つの手法で識別した結果によると、3つ目のクラスタと類似しているのが分かった。ユークリッド距離の場合、三つ目のクラスタに類似していると判断したが、ほかの二つのクラスタの差はあまりない。これに対して、他の2つの手法も三つ目のクラスタに類似していると判断した、さらに残りの2つのクラスタに著しい差がある(表3)。

表3 異なる識別法による識別結果

	ユークリッド	分散が異なる	多項式回帰
C1	30.2	3786	3699
C2	9.5	-1079	-1357
C3	8.4	-2275	-2278

### 5. 今後の計画・展望

人間がスウィングする際に、体の動きも非常に重要である。肩、腰などの部位が無駄なく、力を入れれば、安定なスウィングを行う。今後はボディーの動きを注目し、パターン認識を行う必要がある。そして、類似している上級者のスウィングパターンを用いて、一般者のパターンは上級者のスウィングにどの部分と類似している、どの部分は似ていないのかを明らかにし、どの部分を改善すべきなのかを科学的に分析し、一般者にアドバイスすることを試みる。

文献

- [1] A. K. Jain and R. C. Dubes, Algorithms for clustering data, Prentice Hall, 1988.  
 [2] 渡辺 洋, 「ベイズ統計学入門」. 福村出版社, 2009  
 [3] 太田 憲, 仰木 裕嗣, 木村 広, 「スポーツデータ」2005.