

クラスター分析に関するノート

情報学部 堀田 敬介

2004/7/31 (2008/7/1 改訂, 2009/10/31 改訂)

1 類似度の測定

まずはじめに、各データ間の距離を測るが、尺度毎に様々な方法が提案されている。尺度に対応した類似度測定の距離を示す。

1.1 間隔尺度による類似度の測定

n 個の対象があり、各対象は間隔尺度で m 個の属性 (変量) が測定されているとする。このとき対象 p と q を

$$\mathbf{x}_p = [x_{p1}, \dots, x_{pm}]^T, \quad \mathbf{x}_q = [x_{q1}, \dots, x_{qm}]^T$$

とし、その距離 d_{pq} を測ることを考える。

ユークリッド距離 $d_{pq} = \sqrt{\sum_{i=1}^m (x_{pi} - x_{qi})^2}$

ユークリッド平方距離 $d_{pq} = \sum_{i=1}^m (x_{pi} - x_{qi})^2$

重み付きユークリッド距離 $d_{pq} = \sqrt{\sum_{i=1}^m w_i (x_{pi} - x_{qi})^2}$ $w_i (i = 1, \dots, m)$ は重み (weight)

マンハッタン距離 $d_{pq} = \sum_{i=1}^m |x_{pi} - x_{qi}|$

ミンコフスキー距離 $d_{pq} = \sqrt[k]{\sum_{i=1}^m |x_{pi} - x_{qi}|^k}$

($k = 1$ ならばマンハッタン距離, $k = 2$ ならばユークリッド距離となる)

キャンベラ距離 $d_{pq} = \sum_{i=1}^m \frac{|x_{pi} - x_{qi}|}{|x_{pi}| + |x_{qi}|}$

マハラノビス距離 $d_{pq} = (\mathbf{x}_p - \mathbf{x}_q)^T \Sigma^{-1} (\mathbf{x}_p - \mathbf{x}_q)$
(Σ : 分散共分散行列)

内積 $d_{pq} = \mathbf{x}_p^T \mathbf{x}_q = \sum_{i=1}^m x_{pi} x_{qi}$

(平均 0, 長さ $\|\mathbf{x}_p\| = \|\mathbf{x}_q\| = 1$ に標準化した際の Pearson の積率相関係数に一致)

Pearson の積率相関係数 $r_{pq} = \frac{\sum_{i=1}^m (x_{pi} - \bar{x}_p)(x_{qi} - \bar{x}_q)}{\sqrt{\sum_{i=1}^m (x_{pi} - \bar{x}_p)^2} \sqrt{\sum_{i=1}^m (x_{qi} - \bar{x}_q)^2}}$

1.2 順序尺度による類似度の測定

n 個の対象があり、各対象は順序尺度で m 個の属性（変量）が測定されているとする。このとき対象 p と q を

$$\mathbf{x}_p = [x_{p1}, \dots, x_{pm}]^T, \quad \mathbf{x}_q = [x_{q1}, \dots, x_{qm}]^T$$

とし、各変量は各固体の順位をあらわす数値 $(1, 2, \dots, m)$ になっている場合、どの程度対応する変量の順位が一致しているかを、順位相関係数 r_{pq} で計ることを考える。

$$\text{Spearman の順位相関係数} \quad r_{pq} = 1 - \frac{6}{m(m+1)(m-1)} \sum_{i=1}^m (x_{pi} - x_{qi})^2$$

(上記の順位尺度変量に Pearson の積率相関係数を計算した結果)

$$\text{Kendall の順位相関係数} \quad r_{pq} = 1 - \frac{F - R}{n(n-1)/2}$$

Kendall の相関係数について、 F, R はそれぞれ、

F は $\forall i, j \in \{1, \dots, m\} : (i < j) \quad x_{pi} > x_{pj}$ かつ $x_{qi} > x_{qj}$, または $x_{pi} < x_{pj}$ かつ $x_{qi} < x_{qj}$ の個数

R は $\forall i, j \in \{1, \dots, m\} : (i < j) \quad x_{pi} > x_{pj}$ かつ $x_{qi} < x_{qj}$, または $x_{pi} < x_{pj}$ かつ $x_{qi} > x_{qj}$ の個数

となる。即ち、全変量対 $(n(n-1)/2)$ 個) に対する、順序が同じ個数と逆になる個数の差の割合を意味する。

1.3 名義尺度 ([0,1]-データ) による類似度の測定

n 個の対象があり、各対象は名義尺度で m 個の属性（変量）が測定されており、その値は 1 または 0 であるとする。このとき対象 p, q

$$\mathbf{x}_p = [x_{p1}, \dots, x_{pm}]^T, \quad \mathbf{x}_q = [x_{q1}, \dots, x_{qm}]^T$$

間の類似度 S_{pq} を測定することを考える。

$$\text{類似比 (the coefficient of Jaccard)} \quad S_{pq} = a/(a + b + c)$$

$$\text{一致係数 (the simple matching coefficient)} \quad S_{pq} = (a + d)/m$$

$$\text{Russel-Rao 係数} \quad S_{pq} = a/m$$

$$\text{Rogers-Tanimoto 係数} \quad S_{pq} = (a + d)/(m + b + c)$$

$$\text{Hamann 係数} \quad S_{pq} = \{(a + d) - (b + c)\}/m$$

$$\text{ファイ係数} \quad S_{pq} = (ad - bc)/\{(a + b)(c + d)(a + c)(b + d)\}^{\frac{1}{2}}$$

ただし、

$$a = \sum_{k=1}^m x_{pk} x_{qk} \quad \text{対象 } p, q \text{ がともに } 1 \text{ をとる変量の個数}$$

$$b = \sum_{k=1}^m x_{pk} (1 - x_{qk}) \quad \text{対象 } p \text{ が } 1, q \text{ が } 0 \text{ をとる変量の個数}$$

$$c = \sum_{k=1}^m (1 - x_{pk}) x_{qk} \quad \text{対象 } p \text{ が } 0, q \text{ が } 1 \text{ をとる変量の個数}$$

$$d = \sum_{k=1}^m (1 - x_{pk})(1 - x_{qk}) \quad \text{対象 } p, q \text{ がともに } 0 \text{ をとる変量の個数}$$

であり、

$$a + b + c + d = m$$

となる。

1.4 名義尺度による類似度の測定 (変量間類似度)

n 個の対象があり, 各対象は名義尺度で m 個の属性 (変量) の度数が測定されているとする. 対象 p の属性 i の度数を n_{pi} で表す.

対象 \ 属性	1	...	i	...	m
1	f_{11}	...	f_{1i}	...	f_{1m}
\vdots	\vdots	\ddots	\vdots		\vdots
p	f_{p1}	...	f_{pi}	...	f_{pm}
\vdots	\vdots		\vdots	\ddots	\vdots
n	f_{n1}	...	f_{ni}	...	f_{nm}

平均平方根一致係数 $C = \sqrt{\chi^2 / (\chi^2 + nm)}$
 (χ^2 は 2 つの変量間の独立性検定のためのカイ 2 乗統計量)

グッドマン・クラスカルの λ
$$\lambda = \frac{\sum_p \max_i f_{pi} + \sum_i \max_p f_{pi} - \max_p \sum_i f_{pi} - \max_i \sum_p f_{pi}}{2nm - \max_p \sum_i f_{pi} - \max_i \sum_p f_{pi}}$$

2 クラスタ分析 : クラスタ化の方法

クラスタ p とクラスタ q があわさり一つのクラスタ t を作る場合, 新しくできるクラスタ t と p, q 以外のクラスタ達 (r と呼ぼう) との類似度 S_{tr} を求める必要がある. 今, p と q , p と r , q と r の元の類似度をそれぞれ S_{pq} , S_{pr} , S_{qr} としたときに, これらを基にして S_{tr} を求める方法は, 例えば以下のようなものがある.

1. 最短距離法 (nearest neighbor method)
2. 最長距離法 (furthest neighbor method)
3. 群平均法 (group average method)
4. 重心法 (centroid method)
5. 中央値法 (median method)
6. ウォード法 (Ward method)

ここでは, 上記 6 つのうち, 重心法とウォード法についてのみ記す.

2.1 重心法 centroid method

重心法は, クラスタ間の類似度を各クラスタの重心間の距離で測る方法. クラスタ p, q 間, p, r 間, q, r 間, 及び t, r 間の類似度 S_{pq} , S_{pr} , S_{qr} 及び S_{tr} について,

$$S_{tr} = \frac{n_p}{n_p + n_q} S_{pr} + \frac{n_q}{n_p + n_q} S_{qr} - \frac{n_p n_q}{(n_p + n_q)^2} S_{pq}$$

と更新する方法である。クラスタ p, q, r , 及び t の重心をそれぞれ $\mathbf{x}_p, \mathbf{x}_q, \mathbf{x}_r$, 及び \mathbf{x}_t とし, クラスタ p, q, r , 及び t 内の対象数をそれぞれ n_p, n_q, n_r , 及び n_t とする. すると,

$$\begin{aligned} n_t &= n_p + n_q, \\ \bar{\mathbf{x}}_t &= \frac{n_p}{n_p + n_q} \bar{\mathbf{x}}_p + \frac{n_q}{n_p + n_q} \bar{\mathbf{x}}_q \end{aligned}$$

である. クラスタ t, r 間のユークリッド平方距離を d_{tr}^2 とすると,

$$\begin{aligned} d_{tr}^2 &= \|\bar{\mathbf{x}}_t - \bar{\mathbf{x}}_r\|^2 = \left\| \left(\frac{n_p}{n_p + n_q} \bar{\mathbf{x}}_p + \frac{n_q}{n_p + n_q} \bar{\mathbf{x}}_q \right) - \bar{\mathbf{x}}_r \right\|^2 \\ &= \left\| \frac{n_p}{n_p + n_q} (\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r) + \frac{n_q}{n_p + n_q} (\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r) \right\|^2 \\ &= \frac{n_p^2}{(n_p + n_q)^2} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \frac{n_q^2}{(n_p + n_q)^2} \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - \frac{2n_p n_q}{(n_p + n_q)^2} |(\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r, \bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r)| \\ &= \frac{n_p(n_p + n_q) - n_p n_q}{(n_p + n_q)^2} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \frac{n_q(n_p + n_q) - n_p n_q}{(n_p + n_q)^2} \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - \frac{2n_p n_q}{(n_p + n_q)^2} |(\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r, \bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r)| \\ &= \frac{n_p}{n_p + n_q} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \frac{n_q}{n_p + n_q} \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - \frac{n_p n_q}{(n_p + n_q)^2} \left\{ \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - 2 |(\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r, \bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r)| \right\} \\ &= \frac{n_p}{n_p + n_q} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \frac{n_q}{n_p + n_q} \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - \frac{n_p n_q}{(n_p + n_q)^2} \|(\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r) - (\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r)\|^2 \\ &= \frac{n_p}{n_p + n_q} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_r\|^2 + \frac{n_q}{n_p + n_q} \|\bar{\mathbf{x}}_q - \bar{\mathbf{x}}_r\|^2 - \frac{n_p n_q}{(n_p + n_q)^2} \|\bar{\mathbf{x}}_p - \bar{\mathbf{x}}_q\|^2 \\ &= \frac{n_p}{n_p + n_q} d_{pr}^2 + \frac{n_q}{n_p + n_q} d_{qr}^2 - \frac{n_p n_q}{(n_p + n_q)^2} d_{pq}^2 \end{aligned}$$

となる. 従って, 重心法では, 類似度 S_{tr} としてユークリッド平方距離 d_{tr}^2 をとったときのみ妥当.

2.2 ウォード法 Ward method

クラスタ p とクラスタ q を一つのクラスタ t に統合するとき, 他のクラスタ r との類似度 S_{tr} を決める方法の一つ. クラスタ p に属する対象 j を \mathbf{x}_{pj} と表すことにする.

$$\mathbf{x}_{pj} = \begin{pmatrix} x_{1pj} \\ \vdots \\ x_{mpj} \end{pmatrix} \in \mathbb{R}^m$$

クラスタ p 内の変動 D_p は

$$D_p := \sum_{i=1}^m \sum_{j=1}^{n_p} (x_{ipj} - \bar{x}_{ip})^2 \quad \text{ただし} \quad \bar{x}_{ip} = \frac{1}{n_p} \sum_{j=1}^{n_p} x_{ipj}$$

であり, 全クラスタ内変動 D は, クラスタ数を K として,

$$D := \sum_{p=1}^K D_p$$

で与えられる. またこのとき,

$$D_t = D_p + D_q + \Delta D_{pq} \quad \text{ただし} \quad \Delta D_{pq} = \frac{n_p n_q}{n_p + n_q} \sum_{i=1}^m (\bar{x}_{ip} - \bar{x}_{iq})^2$$

となる。なぜなら、

$$\begin{aligned} n_t &= n_p + n_q, \\ \bar{x}_{it} &= \frac{1}{n_t} \sum_{j=1}^{n_t} x_{itj} = \frac{1}{n_t} \left(\sum_{j=1}^{n_p} x_{ipj} + \sum_{j=1}^{n_q} x_{iqj} \right) \\ &= \frac{n_p}{n_t} \sum_{j=1}^{n_p} x_{ipj} + \frac{n_q}{n_t} \sum_{j=1}^{n_q} x_{iqj} = \frac{n_p}{n_t} \bar{x}_{ip} + \frac{n_q}{n_t} \bar{x}_{iq}. \end{aligned}$$

であることに注意すると、

$$\begin{aligned} D_t &= \sum_{i=1}^m \sum_{j=1}^{n_t} (x_{itj} - \bar{x}_{it})^2 \\ &= \sum_{i=1}^m \sum_{j=1}^{n_t} \{x_{itj}^2 - 2x_{itj}\bar{x}_{it} + \bar{x}_{it}^2\} \\ &= \sum_{i=1}^m \left\{ \sum_{j=1}^{n_p} \{x_{ipj}^2 - 2x_{ipj}\bar{x}_{it} + \bar{x}_{it}^2\} + \sum_{j=1}^{n_q} \{x_{iqj}^2 - 2x_{iqj}\bar{x}_{it} + \bar{x}_{it}^2\} \right\} \\ &= \sum_{i=1}^m \left\{ \sum_{j=1}^{n_p} (x_{ipj} - \bar{x}_{ip})^2 + 2\bar{x}_{ip} \sum_{j=1}^{n_p} x_{ipj} - n_p \bar{x}_{ip}^2 - 2\bar{x}_{it} \sum_{j=1}^{n_p} x_{ipj} + n_p \bar{x}_{it}^2 \right. \\ &\quad \left. + \sum_{j=1}^{n_q} (x_{iqj} - \bar{x}_{iq})^2 + 2\bar{x}_{iq} \sum_{j=1}^{n_q} x_{iqj} - n_q \bar{x}_{iq}^2 - 2\bar{x}_{it} \sum_{j=1}^{n_q} x_{iqj} + n_q \bar{x}_{it}^2 \right\} \\ &= \sum_{i=1}^m \sum_{j=1}^{n_p} (x_{ipj} - \bar{x}_{ip})^2 + \sum_{i=1}^m \sum_{j=1}^{n_q} (x_{iqj} - \bar{x}_{iq})^2 \\ &\quad + \sum_{i=1}^m \left\{ 2n_p \bar{x}_{ip}^2 - n_p \bar{x}_{ip}^2 - 2n_p \bar{x}_{ip} \bar{x}_{it} + n_p \bar{x}_{it}^2 + 2n_q \bar{x}_{iq}^2 - n_q \bar{x}_{iq}^2 - 2n_q \bar{x}_{iq} \bar{x}_{it} + n_q \bar{x}_{it}^2 \right\} \\ &= D_p + D_q + \sum_{i=1}^m \left\{ n_p \bar{x}_{ip}^2 + n_q \bar{x}_{iq}^2 - n_t \bar{x}_{it}^2 \right\} \\ &= D_p + D_q + \sum_{i=1}^m \left\{ n_p \bar{x}_{ip}^2 + n_q \bar{x}_{iq}^2 - \frac{1}{n_t} \left(n_p^2 \bar{x}_{ip}^2 + 2n_p n_q \bar{x}_{ip} \bar{x}_{iq} + n_q^2 \bar{x}_{iq}^2 \right) \right\} \\ &= D_p + D_q + \sum_{i=1}^m \left\{ \frac{(n_t - n_p)n_p}{n_t} \bar{x}_{ip}^2 - \frac{n_p n_q}{n_t} \bar{x}_{ip} \bar{x}_{iq} + \frac{(n_t - n_q)n_q}{n_t} \bar{x}_{iq}^2 \right\} \\ &= D_p + D_q + \frac{n_p n_q}{n_p + n_q} \sum_{i=1}^m (\bar{x}_{ip} - \bar{x}_{iq})^2 \\ &= D_p + D_q + \Delta D_{pq} \end{aligned}$$

だからである。

さて、ウォード法は、全クラスタ内変動 D を最も小さくするのが好ましいとする方法、即ち、各反復のクラスタリング（例えば p, q を統合して t にする）について、その増分（例では ΔD_{pq} ）を最小にすることを考える方法である。

この増分（ ΔD_{pq} ）を類似度 S_{pq} とし、類似度が最も小さいクラスタ同士を統合する。なお、初期状態（すべてのクラスタが1つの対象から構成されている状態）では、この値はユークリッド平方距離の $\frac{1}{2}$ となる。

また，類似度の更新は，次式で与えられる．

$$\begin{aligned}
(\Delta D_{tr} =) \quad S_{tr} &= \frac{n_t n_r}{n_t + n_r} \sum_{i=1}^m (\bar{x}_{it.} - \bar{x}_{ir.})^2 \\
&= \frac{n_t n_r}{n_t + n_r} \sum_{i=1}^m \left(\frac{n_p}{n_t} \bar{x}_{ip.} + \frac{n_q}{n_t} \bar{x}_{iq.} - \bar{x}_{ir.} \right)^2 \\
&= \frac{n_t n_r}{n_t + n_r} \sum_{i=1}^m \left(\frac{n_p^2}{n_t^2} \bar{x}_{ip.}^2 + \frac{n_q^2}{n_t^2} \bar{x}_{iq.}^2 + \bar{x}_{ir.}^2 + \frac{2n_p n_q}{n_t^2} \bar{x}_{ip.} \bar{x}_{iq.} - \frac{2n_p}{n_t} \bar{x}_{ip.} \bar{x}_{ir.} - \frac{2n_q}{n_t} \bar{x}_{iq.} \bar{x}_{ir.} \right) \\
&= \frac{n_r}{n_t + n_r} \sum_{i=1}^m \left\{ n_p (\bar{x}_{ip.}^2 - 2\bar{x}_{ip.} \bar{x}_{ir.} + \bar{x}_{ir.}^2) + n_q (\bar{x}_{iq.}^2 - 2\bar{x}_{iq.} \bar{x}_{ir.} + \bar{x}_{ir.}^2) - \frac{n_p n_q}{n_t} (\bar{x}_{ip.}^2 + 2\bar{x}_{ip.} \bar{x}_{iq.} + \bar{x}_{iq.}^2) \right\} \\
&= \frac{1}{n_t + n_r} \left\{ n_p n_r \sum_{i=1}^m (\bar{x}_{ip.} - \bar{x}_{ir.})^2 + n_q n_r \sum_{i=1}^m (\bar{x}_{iq.} - \bar{x}_{ir.})^2 - n_r \frac{n_p n_q}{n_p + n_q} \sum_{i=1}^m (\bar{x}_{ip.} - \bar{x}_{iq.})^2 \right\} \\
&= \frac{1}{n_t + n_r} \{ (n_p + n_r) \Delta D_{pr} + (n_q + n_r) \Delta D_{qr} - n_r \Delta D_{pq} \} \\
&= \frac{n_p + n_r}{n_t + n_r} S_{pr} + \frac{n_q + n_r}{n_t + n_r} S_{qr} - \frac{n_r}{n_t + n_r} S_{pq}
\end{aligned}$$

2.3 6つの方法を統合する式

G.N. Lance & W.T. Williams による統一的に扱うための式. 各方法の違いを, パラメータ $(\alpha_p, \alpha_q, \beta, \gamma)$ の違いで決定できると示した. 平方距離を使用する場合は2番目の式となる.

$$\begin{cases} S_{tr} &= \alpha_p S_{pr} + \alpha_q S_{qr} + \beta S_{pq} + \gamma |S_{pr} - S_{qr}| \\ S_{tr}^2 &= \alpha_p S_{pr}^2 + \alpha_q S_{qr}^2 + \beta S_{pq}^2 + \gamma |S_{pr}^2 - S_{qr}^2| \quad (\text{平方距離用}) \end{cases}$$

(1) 最短距離法 (nearest neighbor method)

$$\begin{aligned} \alpha_p = \alpha_q &:= \frac{1}{2}, \quad \beta := 0, \quad \gamma := -\frac{1}{2} \\ S_{tr} &= \frac{1}{2} S_{pr} + \frac{1}{2} S_{qr} - \frac{1}{2} |S_{pr} - S_{qr}| \\ &= \begin{cases} S_{pr} & \text{for } S_{pr} \leq S_{qr}, \\ S_{qr} & \text{for } S_{pr} > S_{qr} \end{cases} \\ &= \min\{S_{pr}, S_{qr}\} \end{aligned}$$

(2) 最長距離法 (furthest neighbor method)

$$\begin{aligned} \alpha_p = \alpha_q &:= \frac{1}{2}, \quad \beta := 0, \quad \gamma := \frac{1}{2} \\ S_{tr} &= \frac{1}{2} S_{pr} + \frac{1}{2} S_{qr} + \frac{1}{2} |S_{pr} - S_{qr}| \\ &= \begin{cases} S_{pr} & \text{for } S_{pr} \geq S_{qr}, \\ S_{qr} & \text{for } S_{pr} < S_{qr} \end{cases} \\ &= \max\{S_{pr}, S_{qr}\} \end{aligned}$$

(3) 重心法 (centroid method)

$$\begin{aligned} \alpha_p &:= \frac{n_p}{n_t}, \quad \alpha_q := \frac{n_q}{n_t}, \quad \beta \frac{n_p n_q}{n_t^2}, \quad \gamma := 0 \\ S_{tr}^2 &= \frac{n_p}{n_t} S_{pr}^2 + \frac{n_q}{n_t} S_{qr}^2 - \frac{n_p n_q}{n_t^2} S_{pq}^2 \end{aligned}$$

(4) 中央値法 (median method)

$$\begin{aligned} \alpha_p = \alpha_q &:= \frac{1}{2}, \quad \beta := -\frac{1}{4}, \quad \gamma := 0 \\ S_{tr} &= \frac{1}{2} S_{pr} + \frac{1}{2} S_{qr} - \frac{1}{4} S_{pq} \end{aligned}$$

(5) 群平均法 (group average method)

$$\begin{aligned} \alpha_p &:= \frac{n_p}{n_t}, \quad \alpha_q := \frac{n_q}{n_t}, \quad \beta = \gamma := 0 \\ S_{tr}^2 &= \frac{n_p}{n_t} S_{pr}^2 + \frac{n_q}{n_t} S_{qr}^2 \end{aligned}$$

(6) ウォード法 (Ward method)

$$\begin{aligned} \alpha_p &:= \frac{n_p + n_r}{n_t + n_r}, \quad \alpha_q := \frac{n_q + n_r}{n_t + n_r}, \quad \beta := -\frac{n_r}{n_t + n_r}, \quad \gamma := 0 \\ S_{tr}^2 &= \frac{n_p + n_r}{n_t + n_r} S_{pr}^2 + \frac{n_q + n_r}{n_t + n_r} S_{qr}^2 - \frac{n_r}{n_t + n_r} S_{pq}^2 \end{aligned}$$