

Keeners Ranking Methode



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Tabea Born



Google



1. Einführung

- Motivation
- Idee

2. Keeners Ranking Methode

- Berechnung des Rankings
- Beispiel

3. Was hat Google mit Keeners Ranking-Methode zu tun?



Teil 1:

EINFÜHRUNG

- Streitigkeiten, welches College Football Team das Beste ist
- Umfragen und verschiedene mathematische Ranking-Methoden in Zeitungen sorgen für Verwirrung
- Viele Ranking-Methoden basieren auf Perron-Frobenius Theorem
- Ranking von (College Football) Teams als Möglichkeit, Studenten das Perron-Frobenius Theorem beizubringen

- Verwendung von nicht-negativen Statistiken zur Erstellung des Ratings
- Verknüpfen des *Ratings* eines Teams mit seiner *absoluten Stärke*
- *Absolute Stärke* eines Teams basiert auf seiner *relativen Stärke*
- Annahmen:
 1. Die *Stärke* s eines Teams wird durch Interaktionen mit Gegnern und deren Stärke ermittelt
 2. Das *Rating* r jedes Teams ist proportional zu seiner Stärke, d.h. für ein Team i gilt: $s_i = \lambda r_i$



Teil 2:

KEENERS RANKING METHODE

Schritt 1: Auswahl des Stärke-Attributs a_{ij}

- a_{ij} = Wert der Statistik, die bei einem Wettkampf von Team i gegen Team j erzeugt wurde
 - Beispiele:
 - Anzahl der Spiele, bei dem Team i gegen Team j gewonnen hat
 - Anzahl der Körbe / Tore / Punkte die Team i gegen Team j gemacht hat
 - Sei a_{ij} die Anzahl der Punkte S_{ij} die Team i gegen Team j gemacht hat:
 - Rohe Daten nicht sinnvoll → Offensive Teams haben besseres Ranking
 - Besser: Totale Anzahl der erreichten Punkte verwenden
$$a_{ij} = \frac{S_{ij}}{S_{ij} + S_{ji}}$$
 - Noch besser: Laplace'sche Regel anwenden
$$a_{ij} = \frac{S_{ij} + 1}{S_{ij} + S_{ji} + 2}$$

Schritt 1: Beispiel

- Fußball-WM 2014: Gruppe G
 - Deutschland, Ghana, Portugal, USA
- Statistiken aus den WMen 2006, 2010 & 2014 herangezogen
- a_{ij} = Anzahl der Tore aller Spiele des Teams i gegen das Team j

$a_{ij} = S_{ij}$	Deutschland	Ghana	Portugal	USA
Deutschland	0	3	7	0
Ghana	2	0	0	5
Portugal	1	0	0	2
USA	0	4	2	0

Land	Gespielte Spiele (n_i)
DE	4
GH	5
PT	3
US	4

Schritt 1: Beispiel (Fortsetzung)

- Anwenden der Laplace'schen Regel:

$$a_{ij} = \frac{S_{ij} + 1}{S_{ij} + S_{ji} + 2}$$

a_{ij}	DE	GH	PT	US
DE	0	3	7	0
GH	2	0	0	5
PT	1	0	0	2
US	0	4	2	0



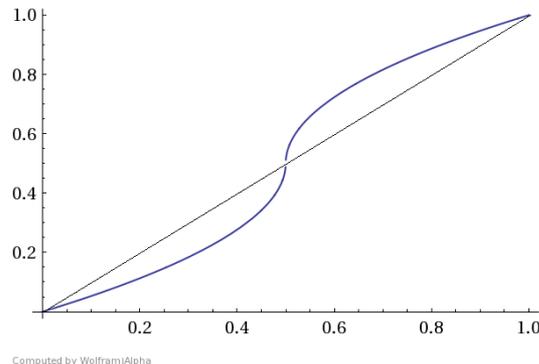
a_{ij}	DE	GH	PT	US
DE	0	4/7	4/5	1/2
GH	3/7	0	1/2	6/11
PT	1/5	1/2	0	1/2
US	1/2	5/11	1/2	0

Schritt 2: „Anpassen“ der Werte

- Kompensieren der „Weil wir es können“-Situation

- Nichtlineare *skewing*-Funktion:
$$h(x) = \frac{1}{2} + \frac{\operatorname{sgn}(x - \frac{1}{2})\sqrt{|2x-1|}}{2}$$

- Mäßigender Effekt auf starke Differenzen im oberen und unteren Bereich
- Künstliche Separierung von Werten, die nahe an $\frac{1}{2}$ liegen



- Möglichkeit, das System für bestimmte Wettkämpfe anzupassen

Schritt 2: Beispiel

- *Skewing* in diesem Fall nicht notwendig!
- Alle Mannschaften etwa gleich stark
 - Teams waren alle bei jeder WM dabei
 - Teams haben meistens wenigstens das Achtelfinale erreicht
- WM-Siege aus vorherigen Jahrzehnten nicht aussagekräftig
 - Komplette andere Mannschaft / anderer Trainer
 - Evtl. Veränderung des Spielverhaltens?

Schritt 3: Normalisieren der Werte

$$a_{ij} \leftarrow \frac{a_{ij}}{n_i}$$

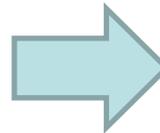


- Nicht jedes Team hat dieselbe Anzahl an Spielen gespielt
- Teams die mehrere Spiele gespielt haben, können mehr Punkte machen
 - Messung der Stärke wird beeinflusst
- ABER:
 - Skewing hat einen normalisierenden Effekt.
 - Wenn Skewing angewendet wird und es keine großen Unterschiede in der Anzahl von gespielten Spielen gibt, ist das Normalisieren nicht nötig
 - Gefahr der Über-Normalisierung!

Schritt 3: Beispiel

- Da nicht alle Teams dieselbe Anzahl an Spielen gespielt haben, muss die Tabelle normalisiert werden:

a_{ij}	DE	GH	PT	US
DE	0	4/7	4/5	1/2
GH	3/7	0	1/2	6/11
PT	1/5	1/2	0	1/2
US	1/2	5/11	1/2	0



a_{ij}	DE	GH	PT	US
DE	0	1/7	1/5	1/8
GH	3/35	0	1/10	6/55
PT	1/15	1/6	0	1/6
US	1/8	5/44	1/8	0

Land	DE	GH	PT	US
Gespielte Spiele (n_i)	4	5	3	4

Schritt 4: Ranking berechnen – Basics

- Organisation der bearbeiteten Daten in eine Matrix:

$$A = [a_{ij}]_{m \times m}, \quad \text{wobei } m = \text{Anzahl der Teams}$$

- Damit können Methoden der Matrixtheorie verwendet werden
- Möglichkeit, ein numerisches Ranking zu erstellen

Schritt 4: Ranking berechnen – Rating

- $r_j(t)$ = numerisches Rating des Teams j zum Zeitpunkt t
- Explizite Zeitangabe t kann vernachlässigt werden
- Daher:

$$r = \begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_m \end{pmatrix} = \text{der Rating-Vektor}$$

Schritt 4: Ranking berechnen – Stärke

- Keeners erste Annahme war:
 - Die *Stärke* s eines Teams wird durch Interaktionen mit Gegnern und deren Stärke ermittelt
- Relative Stärke:
 - Die relative Stärke eines Teams i gegen ein Team j ist definiert durch: $s_{ij} = a_{ij}r_j$
- Absolute Stärke:
 - Die absolute Stärke eines Teams i ist definiert durch: $s_i = \sum_{j=1}^m s_{ij} = \sum_{j=1}^m a_{ij}r_j$
 - Der Stärke-Vektor $s = (s_1 \ s_2 \ \dots \ s_m)^T$ kann auch so ausgedrückt werden:

$$s = \begin{pmatrix} \sum_j a_{1j}r_j \\ \sum_j a_{2j}r_j \\ \vdots \\ \sum_j a_{mj}r_j \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mm} \end{pmatrix} \begin{pmatrix} r_1 \\ r_2 \\ \vdots \\ r_m \end{pmatrix} = Ar$$

Schritt 4: Ranking berechnen – „Knackpunkt“



- Keeners 2. Annahme war:
 - Das *Rating* r jedes Teams ist proportional zu seiner Stärke, d.h. für ein Team i gilt: $s_i = \lambda r_i$
 - Also gilt $s = \lambda r$
- Auf der vorherigen Folie haben wir gesehen: $s = Ar$
- Daraus können wir folgende Gleichung schließen: $Ar = \lambda r$

Schritt 4: Ranking berechnen – „Knackpunkt“

$$Ar = \lambda r$$

- Lineare Algebra:
 - Proportionalitätsvektor $\lambda = \text{Eigenwert}$
 - Rating $r = \text{Eigenvektor}$
- Berechnung des Rankings = Berechnung des Eigenvektors?
 1. Für eine $m \times m$ - Matrix gibt es m verschiedene Eigenwerte λ
 - Wahl des Eigenwerts beeinflusst das Ranking
 2. Eigenwerte λ können komplexe Zahlen sein
 - Eigenvektoren enthalten komplexe Zahlen \rightarrow unbrauchbar
 3. Eigenwerte λ können negative Zahlen sein \rightarrow nicht optimal
 4. Berechnung der Eigenwerte und Eigenvektoren oft schwer
 - Beschränkung der Berechnung auf Näherungswerte bei großen Matrizen

Schritt 4: Ranking berechnen - Bedingungen

- Keener vermeidet genannte Probleme durch drei Bedingungen:

1. Nicht-Negativität

- Die verwendeten Statistiken dürfen keine negativen Zahlen enthalten
- $A = [a_{ij}] \geq 0$ ist eine nichtnegative Matrix

2. Nicht-Reduzierbarkeit

- Zwei Teams i und j müssen miteinander verglichen werden können (auch wenn sie nicht gegeneinander gespielt haben)
- $i \leftrightarrow k_1 \leftrightarrow k_2 \leftrightarrow \dots \leftrightarrow k_p \leftrightarrow j$ mit $a_{ik_1} > 0, a_{k_1k_2} > 0, \dots, a_{kpj} > 0$

3. Primitivität

- Strengere Version der Nicht-Reduzierbarkeit
- Alle Teams müssen durch dieselbe Anzahl an Spielen miteinander verbunden sein

Schritt 4: Ranking berechnen – Erzwingen von Nicht-Reduzierbarkeit und Primitivität

- Setze:

$$A \leftarrow A + E, \text{ wobei } E = \varepsilon e e^T = \begin{pmatrix} \varepsilon & \varepsilon & \cdots & \varepsilon \\ \varepsilon & \varepsilon & \cdots & \varepsilon \\ \vdots & \vdots & \ddots & \vdots \\ \varepsilon & \varepsilon & \cdots & \varepsilon \end{pmatrix}$$

- Dabei ist e eine Spalte voller 1en und $\varepsilon > 0$ ist genügend klein gewählter Wert
- Effekt:
 - es wird ein künstliches Spiel zwischen allen Teams erzeugt
 - ε ist so klein gewählt, dass es die realen Spiele nicht beeinflusst
 - Jedes Team ist jetzt mit jedem anderen Team direkt verbunden

Schritt 4: Ranking berechnen – Perron-Frobenius Theorem

Sei $A = (a_{ij})$ eine reelle $n \times n$ -Matrix mit positiven Einträgen $a_{ij} > 0$ und bezeichne $\lambda_1, \dots, \lambda_n$ die Eigenwerte von A , so dass $|\lambda_1| > |\lambda_2| \geq \dots \geq |\lambda_n|$.
Dann gilt:

1. $\lambda_1 > |\lambda_2| \geq \dots \geq |\lambda_n|$
2. Der Eigenraum zu λ_1 ist eindimensional.
3. Es gibt einen Eigenvektor zu λ_1 , dessen Einträge alle positiv sind.

Schritt 4: Ranking berechnen

1. Prüfen, dass A nicht-reduzierbar ist
2. Eigenwerte und den Eigenvektor zum größten Eigenwert berechnen

1. Mit Hilfe einer Software

- In diesem Fall muss der Eigenvektor angepasst werden:

$$r = \frac{x}{\sum_{i=1}^m x_i}$$

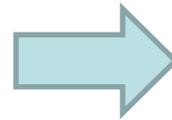
2. Mit Hilfe der Potenzfunktion:

$$r = \lim_{k \rightarrow \infty} \frac{A^k x_0}{\sum_{i=1}^m A^k x_0}$$

Schritt 4: Beispiel

- Matrix A aus den Spieldaten herleiten:

a_{ij}	DE	GH	PT	US
DE	0	1/7	1/5	1/8
GH	3/35	0	1/10	6/55
PT	1/15	1/6	0	1/6
US	1/8	5/44	1/8	0



$$A = \begin{pmatrix} 0 & \frac{1}{7} & \frac{1}{5} & \frac{1}{8} \\ \frac{3}{35} & 0 & \frac{1}{10} & \frac{6}{55} \\ \frac{1}{15} & \frac{1}{6} & 0 & \frac{1}{6} \\ \frac{1}{8} & \frac{5}{44} & \frac{1}{8} & 0 \end{pmatrix}$$

- Eigenwerte λ der Matrix A berechnen:

$$\lambda_1 = -0,13217129761287308 - 0,053341075090507166i$$

$$\lambda_2 = -0,13217129761287308 + 0,053341075090507166i$$

$$\lambda_3 = -0,11074163323656283$$

$$\lambda_4 = 0,375084228462309$$

Schritt 4: Beispiel (Fortsetzung)

- Berechnen des Eigenvektors v für den Eigenwert $\lambda_4 \geq |\lambda_i|$:
 - $\lambda_4 = 0,37508422\dots$

$$v = \begin{pmatrix} 0,5859 \\ 0,4094 \\ 0,5023 \\ 0,4867 \end{pmatrix}$$

- Rating-Vektor ermitteln:

$$r = \begin{pmatrix} 0,5859 \\ 0,4094 \\ 0,5023 \\ 0,4867 \end{pmatrix} \div \sum_{i=1}^4 v_i = \begin{pmatrix} 0,2953 \\ 0,2063 \\ 0,2531 \\ 0,2453 \end{pmatrix}$$

Beispiel - Ergebnis

- Keine Spiele DE ↔ US (seit 2002) oder GH ↔ PT in einer WM
- Ranking der Mannschaften nach Keener:

Für WM 2006 + 2010 + 2014:

Team	Ranking
Deutschland	0,2953
Portugal	0,2531
USA	0,2453
Ghana	0,2063

Nur für WM 2014:

Team	Ranking
Deutschland	0,2886
USA	0,2661
Ghana	0,2403
Portugal	0,2050

- Was bedeutet das für die Spiele DE ↔ US und GH ↔ PT?

Was bedeutet das für die Spiele DE ↔ US und GH ↔ PT?

- Rankings kein objektives Abbild der Realität:
 - Keine lineare Relation zwischen Ranking und realen Spielen
 - Viele Faktoren werden nicht berücksichtigt (z.B. Heimvorteil, Verletzungen, ...)
 - Aufstellung und Taktik der Mannschaft verändert sich
 - Spiele mit Gleichstand werden in dem Beispiel nicht berücksichtigt
 - ...
- Es ist nicht möglich, eine klare Aussage über den Spielausgang zu treffen



Teil 3:

WAS HAT GOOGLE MIT KEENERS RANKING-METHODE ZU TUN?

Was hat Google mit Keeners Rating-Methode zu tun?

- PageRank-Algorithmus
- Erstellt ein Ranking über Wichtigkeit von Webseiten
 - Genauer: Die Wichtigkeit einer Seite hängt von der Wichtigkeit der Seiten ab, die Links zu dieser Seite haben
- Logik ähnlich der von Keeners Rating-Methode
 - Es wird eine Hyperlink-Matrix definiert
 - Danach wird der Eigenwert bzw. der Eigenvektor zu Berechnung des Rankings ermittelt
- Perron-Frobenius Theorem hilft dabei, ein positives Ranking zu erhalten



VIELEN DANK FÜR EURE AUFMERKSAMKEIT



- Literatur:

- Who's #1? - The Science of Rating and Ranking, Kapitel 4
- The Perron-Frobenius theorem and the ranking of football teams, James Keener
- PageRank-Methode: Mathematik für Informatiker, Springer Verlag

- Bilder:

- Keener: http://www.math.utah.edu/~keener/pictures_of_me/DSCN1349.JPG
- Google: http://www.seo-united.de/blog/wp-content/uploads/2013/09/google_logo_2013.png
- Football Team: http://dailyemerald.com/wp-content/uploads/2013/11/131116.RJK_OEM_FBC_Utah_1689.jpg
- WM-Pokal: http://ssfkappishaeusern.de/assets/images/FifaPokal_WEB.JPG