

Definition

Für eine stochastische Sprache $M \subseteq \Sigma^*$ mit Buchstabenhäufigkeiten p_s heißt

$$\kappa_M := \kappa_{MM} = \sum_{s \in \Sigma} p_s^2$$

der **Koinzidenzindex** von M (nach FRIEDMAN).

Deutung: Für unabhängige Texte $a, b \in M$ gleicher Länge ist

$$\kappa(a, b) \approx \kappa_M$$

Beispiele. 1.) $\kappa_{\Sigma^*} = 1/n$. Im Spezialfall $n = 26$ ist $\kappa_{\Sigma^*} \approx 0.0385$.

2.) Aus den bekannten [Häufigkeitstabellen](#) folgen empirisch die [bereits angekündigten](#) Werte

- für $M = \text{»Deutsch«}$: $\kappa_M \approx 0.0762$,
- für $M = \text{»Englisch«}$: $\kappa_M \approx 0.0661$.

Eigenschaften

Da $\sum_{s \in \Sigma} p_s = 1$, gilt $1/n \leq \kappa_M \leq 1$, und zwar

- $\kappa_M = 1/n \Leftrightarrow$ alle $p_s = 1/n$,
- $\kappa_M = 1 \Leftrightarrow$ ein $p_s = 1$, alle übrigen = 0.

Das folgt aus

$$a. 1 = (\sum_{s \in \Sigma} p_s \cdot 1)^2 \leq \sum_{s \in \Sigma} p_s^2 \cdot \sum_{s \in \Sigma} 1 = n \cdot \sum_{s \in \Sigma} p_s^2$$

mit Gleichheit $\Leftrightarrow (p_s)_{s \in \Sigma} = c \cdot (1)_{s \in \Sigma}$ (als Vektor) \Leftrightarrow alle p_s gleich \Leftrightarrow alle $p_s = 1/n$.

$$b. \sum_{s \in \Sigma} p_s^2 \leq \sum_{s \in \Sigma} p_s = 1, \text{ da } 0 \leq p_s \leq 1, \text{ also } p_s^2 \leq p_s,$$

mit Gleichheit \Leftrightarrow alle $p_s^2 = p_s \Leftrightarrow$ alle $p_s = 0$ oder 1.

Anwendungen

1.) Bei polyalphabetischer Substitution ist die Wiederverwendung des gleichen Schlüssels mit hoher

Wahrscheinlichkeit erkennbar (egal, ob periodisch oder nicht):

Für *verschiedene* polyalphabetische Substitutionen f, g ist zu erwarten, dass

$$\kappa(f(a),g(b)) \approx 1/n \quad \text{für } a, b \in \Sigma^r.$$

Jetzt ist auch geklärt, dass bei *gleicher* Substitution

$$\kappa(f(a),f(b)) = \kappa(a,b) \approx \kappa_M \quad \text{für } a, b \in M.$$

2.) Sei c ein Geheimtext aus einer polyalphabetischen Verschlüsselung eines Textes $a \in M$ der Periode l . Welche Werte sind für $\kappa_q(c)$ zu erwarten?

$$\begin{array}{cccc|c|cccc} c = c_0 & \dots & c_{q-1} & & c_q & \dots & c_{r-1} \\ c(q) = c_{r-q} & \dots & c_{r-1} & & c_0 & \dots & c_{r-q-1} \\ \text{erwartete Koinzidenzen: } q \cdot \kappa_M, & \text{falls } l|r-q, & & & (r-q) \cdot \kappa_M, & \text{falls } l|q, \\ & q \cdot \kappa_{\Sigma^*} \text{ sonst,} & & & & (r-q) \cdot \kappa_{\Sigma^*} \text{ sonst.} \end{array}$$

Daraus ergeben sich folgende erwartete Werte für den Autokoinzidenzindex:

1. Fall, $l|r$:

$$\kappa_q(c) \approx \frac{q \cdot \kappa_M + (r-q) \cdot \kappa_M}{r} = \kappa_M, \quad \text{falls } l|q,$$

$$\kappa_q(c) \approx \frac{q \cdot \kappa_{\Sigma^*} + (r-q) \cdot \kappa_{\Sigma^*}}{r} = \kappa_{\Sigma^*} \quad \text{sonst.}$$

2. Fall, l kein Teiler von r :

$$\kappa_q(c) \approx \frac{q \cdot \kappa_{\Sigma^*} + (r-q) \cdot \kappa_M}{r} \quad \text{falls } l|q,$$

$$\kappa_q(c) \approx \frac{q \cdot \kappa_M + (r-q) \cdot \kappa_{\Sigma^*}}{r} \quad \text{falls } l|r-q,$$

$$\kappa_{\Sigma^*} \quad \text{sonst.}$$

Insbesondere gilt für $q \ll r$:

$$\kappa_q(c) \approx \begin{cases} \kappa_M, & \text{wenn } l|q, \\ \kappa_{\Sigma^*} & \text{sonst.} \end{cases}$$

Damit ist auch das im Beispiel beobachtete Autokoinzidenzspektrum erklärt, und die typischen Autokoinzidenzspektren sehen so aus.