

I Codierung ohne haenden

1. Allgemeines über Codes:

- Daf: 1. Zeichen sind Elemente einer endlichen Menge von untersch. Dingen.
 Diese Menge nennt man Zeichenvorrat oder Alphabet.
 Diese Dinge können Lichtimpulse, Magnetschw., Spannungen, Töne usw. sein.
- 2 Ein Wort besteht aus Zeichen eines Alphabets.
 Die Wortlänge gibt an, wieviele Zeichen des Alphabets das Wort hat.
3. M sei ein Alphabet. Dann ist M^* die Menge aller Worte die sich durch Zeichen dieses Alphabets darstellen lassen.
4. Es seien A, B Alphabet. Dann ist die Codierung von Zeichen aus A nach Werten nach B^* definiert durch eine injektive Abb. $\varphi: A \rightarrow B^*$
 d.h. jedem Wort $a \in A$ wird genau ein Wort aus B^* zugeordnet und jedem Wort aus B^* entspricht genau ein Zeichen aus A .

Beispiel: 7 Bit ASCII-Code:

$$R = \{0000000, 0000001, \dots, 1111111\}, R \subseteq A \cdot \text{Großkugel}$$

5. Codierung v. Werten aus A

Es seien A und B Alphabete und es gelte $\varphi(a) \in B^*$ für $a \in A$.

Es sei a_1, a_2, \dots, a_n ein Wort aus A . Dann ist $\varphi^*: A^* \rightarrow B^*$ def. durch:

$$\varphi(a_1, a_2, \dots, a_n) = \varphi(a_1)\varphi(a_2)\varphi(a_3)\dots\varphi(a_n)$$

Beispiel: Ostermann $\in A^*$, $a_i \in A$, $\varphi(\text{Ostermann}) = \varphi(0)\varphi(s)\varphi(t)\dots\varphi(n)$

$\varphi(a_i) \rightarrow B^*$ ist eine injektive Abb., $\varphi^*(A^*) \rightarrow B^*$ muss keine inj. Abb. sein.

6. Ein Alphabet mit nur 2 Zeichen heißt binäres Alphabet

Ein. " " " " " trinäres Alphabet usw.

Es sei B ein Alphabet mit q Zeichen, dann schreibt man $q = |B|$

Beispiel: a) Binäre Alphabete: Dient Verwendung man in technischen Bereichen um mit Computern zu arbeiten.

b) q -äre Alphabete: Alphabete mit $q > 2$ verwendet man in d. Biologie, Physik, etc.
 Wenn man mit einem zum Problem passenden Alphabet arbeitet (natürlich fallsig $q \geq 2$)

2. Decodieren:

Man hat einen Wert von B^* und möchte genau das Urbild des Wertes haben.

a) Das Urbild ist ein Zeichen von A . Da $\varphi: A \rightarrow B^*$ eine injekt. Abb. ist das Urbild eindeutig bestimmt

b) Das Urbild sei ein Wort über A z.B. der Wert $a_1 a_2 a_3 \dots a_n$, $\varphi(a_1 \dots a_n) = \varphi(a_1) \dots \varphi(a_n) \in B^*$

Man kann nur decodieren, wenn man die Nahststellen zwischen den Werten

$\varphi(a_j) \varphi(a_j)$ kennt

$\varphi(a_i)$, $a_i \in A$ nennt man Codewort.

a) Codes mit fester Wortlänge

→ die Nahststellen zw. den Codewörtern kann man durch Abzählen J. Zeichen aus B finden.

→ $\varphi^*: A^* \rightarrow B^*$ ist eine inj. Abb. → decodierbar (eindeutig)

b) Codes mit variabler Wortlänge

Hier lässt sich die Nahststelle der einzelnen Codeworte nicht immer finden.

Beispiel: -Codes mit fester Wortlänge:

- 1) 7-Bit-ASCII-Code (728 Zeichen → 26 groß, 27 Klein Lat., 28 Sonder, 10 Ziffern, 32 Steuer, 6...)
- 2) Teletypeschreibe-Code (8-Bit-Code, 5 Bit Info, 1 Start, 1 Stop)
- 3) Lochstreifen-Code (7 Bit Info, 1 Bit für Lesefehler)
- 4) 8-Bit EBCDIC-Code (Zeichensatz wie ASCII-Code + 1 Bit)
- 5) 12-Bit Lochkarten-Code usw

-Codes mit variabler Wortlänge:

Morsecode: Alphabet hat 3 Zeichen (B) z.B. k. L. pause.

Beispiele:

Es sei $A = \{a_1, a_2, a_3, a_4\}$, $B = \{0, 1\}$

a)	$a_1 \mid 00$	$a_2 \mid 01$	$a_3 \mid 10$	$a_4 \mid 11$
	$a_2 \mid 01$	$a_3 \mid 10$	$a_4 \mid 11$	$a_1 \mid 00$
	$a_3 \mid 10$	$a_4 \mid 11$	$a_1 \mid 00$	$a_2 \mid 01$
	$a_4 \mid 11$	$a_1 \mid 00$	$a_2 \mid 01$	$a_3 \mid 10$

Beispiel a: feste Wortlänge \Rightarrow decodierbar.

Beispiel b bis d: Man betrachte die Folgen v. Codeworten.

b) $\varphi(a_1, a_2, a_3, 0_4) = 0101101111$ bei Code b

c) $\varphi(\quad) = 01001100$ bei Code c

d) $\varphi(\quad) = 0100110000100000110$ bei Code d

Man betrachte die Wortfolge g unter dem Code c: $\varphi(a_1, a_2, a_3, a_4) = \frac{01001100}{1111} = \frac{01001100}{1111} = \frac{01001100}{1111} = 01001100$
 \Rightarrow nicht decodierbar da Nullstelle n. eindeutig.

Man betrachte die Wortfolge p unter dem Code b: 0100011000... ankommende Bitfolge

Bei diesem Code ist Decodieren n. möglich, wenn man ein Wortende findet.

Von diesem Wortende lässt sich d. Code v. rechts nach links decodieren.

Man betrachte die Fälle: 1) 01000110000010..., 2) 01000110000110...

zu 1): 4 mal 0 \Rightarrow Wort fängt mit 0 an. 3 Zeichen 0 \Rightarrow Ende. $\Rightarrow 010001100001010...$

zu 2): $01000110000110 \dots = 010001100010110 \dots$

\Rightarrow links \rightarrow rechts nicht decodierbar

Def: Suffixcode:

Bei einem Suffixcode ist kein Codewort Endstück eines anderen Codewortes.

Satz: Ein Suffixcode ist immer decodierbar. Es lässt sich nur v. rechts nach links decodieren.

Beim Suffixcode hat man eine Vorfärgung beim Decodieren (da rechts \rightarrow links)

Präfixcode:

Def (Fano-Bedingung): Ein Code heißt Präfixcode, wenn kein Codewort Anfangsstück eines anderen Codewortes ist.

Satz: Ein Präfixcode ist ohne Vorfärgung decodierbar. (Code b ist Präfixcode)

Präfixcodes werden automatisch decodiert mit dem Codebaum:



Der Codebaum:

Es sei B ein Alphabet mit $q := |B|$. Es sei $C = \{a_1, \dots, a_n\}$ ein Code über B^* .

Man startet mit der Wurzel. Die Wurzel und jeder Knoten d. Baumes hat maximal q Kinder.
Man trägt die Codeworte in diesen Codebaum ein. Die Urbilder der Codeworte liegen auf Knoten oder Blättern des Baumes. Alle Wege, die zu keinem Urbild eines Codewortes führen, werden aus dem Baum gestrichen.

\Rightarrow Liegen alle Urbilder der Codeworte auf Blättern des Codebaumes, dann hat man einen Präfixcode. Der Code ist eindeutig decodierbar.

Man startet die Decodierung, indem man von der Wurzel den Baum durchläuft bis zu einem Blatt. Damit ist der 1. Codewort decodiert.

Das Urbild steht in dem Blatt. Dann startet man neu. Endet man wieder auf einem Blatt, dann hat man das Urbild des nächsten Codewortes.

Liegt das Urbild eines Codewortes auf einem Knoten und nicht in einem Blatt, dann hat man keinen Präfixcode. Der Code ist dann nicht immer eindeutig decodierbar.

Beispiel b: $q = |B| = 2$, $B = \{0, 1\}$



Die Urbilder der Codeworte liegen auf Blättern. Man hat einen Präfixcode. Der Code ist eindeutig decodierbar.

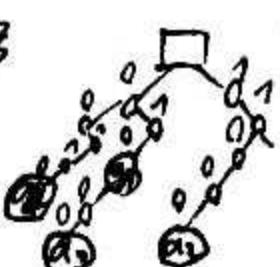
Beispiel c: $q = |B| = 2$, $B = \{0, 1\}$



Ein Urbild liegt nicht auf einem Blatt, sondern auf einem Knoten.

\Rightarrow Der Code ist kein Präfixcode!
Es kann hier keine Aussage über d. Decodierung gemacht werden.

Beispiel d: $q = |B| = 2$, $B = \{0, 1\}$



Nicht alle Urbilder liegen auf Blättern.
 \Rightarrow der Codebaum liefert keine Aussage über d. Decodierung

Ein Suffixcode ist (eindeutig) decodierbar. Ein Suffixcode von hinten gesehen (rechts \rightarrow links) ist ein Präfixcode \Rightarrow Man kann einen Suffixcode mit dem Codebaum decodieren

Beispiel d: $\begin{array}{c} 0 \\ \swarrow \searrow \\ 0 & 1 \\ \swarrow \searrow \swarrow \searrow \\ 0 & 1 & 0 & 1 \end{array}$ \Rightarrow Alle Urbilder liegen auf Blättern. Der Code ist über dem Codebaum (eindeutig) decodierbar.

Andere Codes als Präfix- und Suffixcode decodierbar?

Die Nahtstelle zwischen 2 Codeworten muss erkennbar sein.

Beispiel: $c = \{1, 101, 1001, 10001\}$

Der Code c ist kein Präfixcode und auch kein Suffixcode. genau zwischen den Bits 11 liegt die Nahtstelle zwischen 2 Codeworten \Rightarrow Der Code ist decodierbar

Satz von Sardina Patterson:

Es sei B ein Alphabet mit $q = |B| \geq 2$. B^* sei die Menge aller Worte über B . B^+ sei identisch mit B^* ohne das leere Wort. Es sei c ein Code über B : $c = \{a_1, \dots, a_n\}, a_i \in B^*$.

Es sei $\tilde{S}_1 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_{i-1} \text{ mit } w_2 = w_1 w\}$

$\tilde{S}_2 = \{w \in B^+ \mid \exists w_1 \in S_{i-1} \text{ und } \exists w_2 \in c \text{ mit } w_2 = w_1 w\}$. Es sei: $s = \cup S_i$

$\tilde{S}_3 = \{w \in B^+ \mid \exists w_1 \in S_{i-1} \text{ und } \exists w_2 \in c \text{ mit } w_2 = w_1 w\}$

Der Code ist eindeutig decodierbar $\Leftrightarrow c \cap s = \emptyset$

Problem: Wie weit muss man die S_i berechnen, um s abzubilden zu können?

Abbruchbedingungen:

1. Gilt für ein i_0 : $S_{i_0} = \emptyset$, dann gilt $S_i = \emptyset \forall i \geq i_0$

2. Gilt für ein i_0 : $S_{i_0} = S_{i_0+1}$, dann $S_{i_0+h} = S_{i_0} \forall h \in \mathbb{N}$.

3. Gilt für ein i_0 : $S_{i_0+j} = S_{i_0} \quad j > 1$, dann $\forall r = 0(1)(j-1) \Rightarrow$ Nur für S_{i_0+r} die S_i berechnen

4. Gilt für ein $S_{i_0} \subset \cap S_{i_0+j} \neq \emptyset$ dann ist der Code nicht decodierbar.

Beispiel: Es sei $c = \{010, 1100, 0100, 00110\}$. Man startet mit $S_0 = c$

1. Berechnung v. S_1 : $\tilde{S}_1 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_0 \text{ mit } w_2 = w_1 w\}$

$$w_1 = 010 \Rightarrow w_2 = 01000 \Rightarrow w = 00$$

$$w_1 = 1100 \Rightarrow \cancel{w_2}$$

$$w_1 = 0100 \Rightarrow \cancel{w_2}$$

$$w_1 = 00110 \Rightarrow \cancel{w_2}$$

$$\tilde{S}_1 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_0 \text{ mit } w_2 = w_1 w\} = \emptyset$$

2. Berechnung v. S_2 : $\tilde{S}_2 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_1 \text{ mit } w_2 = w_1 w\}$

$$\tilde{S}_2 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_1 \text{ mit } w_2 = w_1 w\}$$

$$w_1 = 010 \Rightarrow \cancel{w_2}$$

$$w_1 = 1100 \Rightarrow \cancel{w_2}$$

$$w_1 = 0100 \Rightarrow \cancel{w_2}$$

$$w_1 = 00110 \Rightarrow \cancel{w_2}$$

$$\tilde{S}_2 = \{w \in B^+ \mid \exists w_1 \in c \text{ und } \exists w_2 \in S_1 \text{ mit } w_2 = w_1 w\} = \emptyset$$

3. Berechnung v. S_3 : ... $\Rightarrow S = \{00, 110\} \Rightarrow c \cap s = \emptyset$

Ein nicht decodierbarer Code lässt sich häufig durch Hinzufügen eines passenden Präfix oder Suffix in einen decodierbaren Code umwandeln. Hierbei wird aber die Wortlänge verändert.

Beispiel: $a_1 = 0, a_2 = 010, a_3 = 01, a_4 = 10 \Rightarrow a_4$ Suffix v. a_2, a_3 Suffix v. a_1, a_4 , Präfix v. a_2, a_3

Es gilt $a_1 a_2 = a_2 \Rightarrow$ Code nicht decodierbar.

Man hängt an jedes Codewort die Endung 01 an

$\Rightarrow a_1 = 001, a_2 = 01001, a_3 = 0101, a_4 = 1001 \Rightarrow$ Präfixcode.

Satz vom Ungleichung von McMillan:

Es sei B ein Alphabet mit $q = |B| \geq 2$. Sei c ein Code über B^* mit Codeworten $a_i \in B^*$

Die Codeworte a_i haben die Wortlängen n_i .

Der Code sei eindeutig decodierbar. Dann gilt $\sum_{i=1}^n q^{-n_i} \leq 1$ für die Codeworte (a_1, \dots, a_n)

Dies ist eine notwendige Bedingung für die Decodierbarkeit

Beweis:

$$\text{Es sei nun } n_1, n_2, \dots, n_m = k, \quad z = \sum_{i=1}^k q^{-n_i}. \quad z^2 = z \cdot z = \sum_{i=1}^k q^{-n_i} \sum_{j=1}^k q^{-n_j} = \sum_{k=1}^{k^2} q^{-k} f(z, k)$$

$$= \sum_{k=1}^{k^2} q^{-k} f(z, k) \text{ mit } f(z, k) = 0 \text{ für } k < i \text{ ist } \Rightarrow f(z, k) \leq q^k$$

Dies ist eine obere Schranke über die maximale Anzahl von verschiedenen Werten.

$$z^2 \leq \sum_{k=0}^{k^2} q^{-k} q^k, \quad (z)^k = \sum_{k=0}^{k^2} q^{-k} f(z, k), \quad k = n_1 + n_2 + \dots + n_m$$

$f(z, k) \leq q^k$ maximaler Unterschied, d.h. hier Unterschied an jedem Zeichen

$$z = \sqrt[2]{z^2} \leq \sqrt[2]{(z)^k}, \quad z \leq \lim_{k \rightarrow \infty} \sqrt[k]{(z)^k} = 1 \Rightarrow z \leq 1$$

Satz: Ungleichung von Kraft

Es sei B ein Alphabet mit $q = |B| \geq 2$. Es seien n_1, \dots, n_m m natürliche Zahlen.

und es gelte $\sum_{i=1}^m q^{-n_i} \leq 1$.

Dann ex. ein Präfixcode mit Codeworten v. B^* und den Codewortlängen n_i .

Beweis:

$$\max_{i=1}^m n_i = l, \quad m(i) : \text{Anzahl aller } n_i \text{ mit } i = n_i. \quad z = \sum_{i=1}^m q^{-n_i} = \sum_{i=1}^l m(i) q^{-i} \leq 1 / q^l$$

$$\sum_{j=1}^l m(j) q^{l-j} = m(l) q^{l-l} + \sum_{j=1}^{l-1} m(j) q^{l-j} \leq q^l \Rightarrow 1 \leq m(l) \leq q^{l-l} \sum_{j=1}^{l-1} m(j) q^{l-j}, \quad (m(l) \leq q^{l-l} \sum_{j=1}^{l-1} m(j) q^{l-j})$$

$$0 \leq q^{l-1} \sum_{j=1}^{l-1} \mu(j) q^{l-j} : q \Rightarrow 0 \leq q^{l-1} - \mu(l-1) q^{l-1-(l-1)} - \sum_{j=1}^{l-2} \mu(j) q^{l-1-j} (+\mu(l-1))$$

$$0 \leq \mu(l-1) < q^{l-1} - \sum_{j=1}^{l-2} \mu(j) q^{l-1-j} : q \Rightarrow 0 \leq \mu(3) < q^3 - \mu(2) q - \mu(1) q^2 : q$$

$$0 \leq q^2 - \mu(2) - \mu(1) q (+\mu(2)) \Rightarrow 0 \leq \mu(2) < q^2 - \mu(1) q : q$$

$$\Rightarrow 0 \leq q - \mu(1) + \mu(1) \Rightarrow \mu(1) \leq q. \text{ Nun Codebaum! Wurzel: } q \text{ Kinder.}$$

$\mu(1)$ dieser Kinder macht man zu Blättern. Hier schreibt man Urbilder der Codeworte Länge 1 rein. Es bleiben $q - \mu(1) > 0$ Kinder, die zu Knoten werden.

Jetzt dieser Knoten hat q Kinder. \Rightarrow 2te Stufe: $(q \cdot \mu(1))q$ Kinder

Dann $\mu(2)$ Kinder zu Blättern. Möglich? $\exists \mu(2) < q^2 - \mu(1)q \Rightarrow \mu(2) < (q - \mu(1))q \Rightarrow$ mehr Kinder als Blätter. Man macht $\mu(2)$ Kinder zu Blättern und $(q - \mu(1))q - \mu(2)$ Kinder zu Knoten.

Jeder Knoten hat q Kinder. \Rightarrow 3. Stufe $((q - \mu(1))q - \mu(2))q$ Kinder = $q^3 - \mu(2)q^2 - \mu(1)q$

Davon $\mu(3)$ Blätter. Möglich. $\mu(3)$ Kinder z. Blätter, Rest Knoten, usw.

Hiermit ist ein Präfixcode konstruiert mit den Wortlängen $n_i, i = \tau(r) \dots n$

Anwendung:

Man hat einen eindeutig decodierbaren Code. Dieser Code sei schwer decodierbar. Mit dem Satz von Kraft konstruiert man sich einen Präfixcode mit den gleichen Wortlängen. Dieser Code ist einfach decodierbar.

Beispiel:

Die Ungleichung v. McMillan ist nur eine notwendige Bedingung für einen eindeutig decodierbaren Code über B mit $|B|=q=2$. Es sei $C = \{010, 0100, 101\}$ code \Rightarrow McMillan genügt.
 $Z = \sum_{i=1}^3 q^{-n_i} = 2^{-3} + 2^{-4} + 2^{-2} = \frac{7}{16} < 1. 010, 0100, 10 = 010101010$

Informationstheorie von Schlangen:

Man betrachte eine Nachrichtenquelle oder auch einfach Quelle.

Die Quelle gibt Signale von sich. Man möchte diese Signale codieren, um sie zu konservieren. Man unterscheidet zwischen:

- a) Kontinuierliche Quelle (kont. Signale)
- b) diskrete Quelle (diskrete Signale)

Man betrachte endlich viele verschiedene Signale aus diskreten Quellen. \Rightarrow Signale bilden A .

Um die Auftreffswahrscheinlichkeit der Signale zu erfassen, arbeitet man mit dem Wahrscheinlichkeitsraum $S = (A, p)$.

$p(a)$ für $a \in A$ gibt an (wie häufig (rel. Häufigkeit) Signal a auftritt) mit welcher Wahrsch. ...

Man unterscheidet zwischen:

- 1) diskrete Quellen mit Gedächtnis. Hier ist p abh. v. vorher & nachher ges. Zeichen.
- 2) diskrete Quellen ohne Gedächtnis. Hier k. Abh. v. ges. Zeichen.

Jetzt Quellen ohne Gedächtnis \Rightarrow Wahrsch. auf rel. Häufigkeit

Es gilt nun: $0 \leq p(a_i) \leq 1 \quad \forall a_i \in A. \quad p(a_i) = 1$, falls 100%, $p(a_i) = 0$, falls 0%.

Informationsgehalt eines Zeichens

Der Informationsgehalt eines Zeichens $I(a)$, $a \in A$ ist der Informationszuwinn, wenn das Zeichen a aus der Quelle ausgegeben wird. Es gilt:

1) Ist $a \in A$ selten auftretend, dann Inf. gewinn sehr groß, da unerwartet

2) Der Inf. gewinn einer Zeichenkette $I(a_1, a_2, \dots, a_k) = \sum_{i=1}^k I(a_i)$

3) Der Inf. gewinn eines Zeichens, das jetzt kommen muss, ist 0, da erwartet und eingeplant.

Die einfachste Funktion, die diese Bedingungen am Inf. gehalt beschreibt, ist $I(a) = \log_2 \left(\frac{1}{p(a)} \right), a \in A$. $I(a)$ ist bis auf konstanten Faktor eindeutig bestimmt. Es gilt $\frac{I(b)}{I(a)} = \frac{\log_2(p_b)}{\log_2(p_a)}$

Beispiel:

In der Deutschen Sprache tritt der Buchstabe θ mit Wahrscheinlichkeit $0,016$ auf.

$$\Rightarrow I(\theta) = \log_2 \left(\frac{1}{0,016} \right) = \log \frac{1}{0,016} = 5,97$$

Def: Mittlerer Informationsgehalt

Der mittlere Inf. gehalt einer Quelle mit $S(A, p)$ ist def. durch:

$$H(S) = \sum_{a \in A} p(a) \log \frac{1}{p(a)} = \sum_{a \in A} p(a) I(a) = - \sum_{a \in A} p(a) \log(p(a))$$

Die Entropie des endlichen Wahrscheinlichkeitsraumes $S = (A, p)$ ist def. durch:

$$H(S) = - \sum_{a \in A} p(a) \log(p(a)) \quad (\text{in Physik Maß für Unordnung eines Systems})$$

Quellencodierung:

a) Um die Quelle zu erfassen und zu konservieren, später weiter verarbeiten.

b) Quelle zu erfassen und komprimiert abzuspeichern

Jetzt weiter mit b).

Es sei $\varphi: A \rightarrow B^*$ ein Code. Die Wortlänge von $\varphi(a)$, $a \in A$ sei $\lambda(\varphi)$.
 Dann ist die mittlere Wortlänge def. durch $\bar{\lambda}(\varphi, s) = \sum_{a \in A} p(a) \lambda(\varphi)$

Satz: Es gilt: (B Alphabet, $\varphi: A \rightarrow B^*$, $|B| = q$)

$$1) \bar{\lambda}(\varphi, s) \geq H(s) / \log(q)$$

$$2) \bar{\lambda}(\varphi, s) = H(s) / \log(q) \Rightarrow p(a) = q^{-\lambda(\varphi(a))} \quad \forall a \in A$$

Beweis:

Der Code sei eindeutig decodierbar. $\Rightarrow z = \sum_{a \in A} q^{-\lambda(\varphi(a))} \leq 1$ (McMillan), $M(a) = \frac{q^{-\lambda(\varphi(a))}}{z}$

$$\begin{aligned} \text{Es gilt: } H(s) &= \sum_{a \in A} p(a) \log \left(\frac{1}{p(a)} \right) \stackrel{?}{\leq} \sum_{a \in A} p(a) \log \left(\frac{1}{M(a)} \right) (\Leftarrow) \sum_{a \in A} p(a) \left[\log \frac{1}{p(a)} - \sum_{a \in A} p(a) \log \frac{1}{M(a)} \right] \stackrel{?}{\leq} 0 \\ &= \sum_{a \in A} p(a) \left[\log \left(\frac{M(a)}{p(a)} \right) - 1 \right] \Leftarrow 0 \end{aligned}$$