


PROSEMINAR KODIERUNGSTHEORIE 2021

bei Prof. Dr. Klopsch



Thema: Encoding and decoding with a linear code (Chapter 6)

Dea Dubovci, 17.05.21

http://www.goodreads.com/book/show/746828.A_First_Course_in_Coding_Theory

1. Verschlüsseln eines linearen Codes

Def 1.1. Sei C ein $[n, k]$ -code über $GF(q)$ mit Generatormatrix G . Eine **Nachricht** ist ein k -Tupel von $V(k, q)$. Ein **Nachrichtsvektor** $u = u_1 \dots u_k$ wird verschlüsselt, indem man ihn lediglich von rechts mit G multipliziert.

Sei $G = [r_1 | r_2 | \dots | r_k]$, dann:

$$uG = \sum_{i=1}^k u_i r_i$$

d.h. uG ist ein **Codewort** von C , denn es ist eine Linearkombination der Spalten $[r_1 | r_2 | \dots | r_k]$ von G .

Bem. 1.2. Die **Verschlüsselungsfunktion** $u \rightarrow uG$ ordnet dem Vektorraum $V(k, q)$ einem k -dimensionalen Unterraum (nämlich dem Code C) zu.

Satz 1.3. Sei G in Standardform mit $G = [I_k | A]$, wobei $A = [a_{ij}]$ eine $k \times (n - k)$ Matrix ist. Dann wird der Nachrichtsvektor u durch

$$x = uG = x_1x_2 \dots x_k x_{k+1} \dots x_n$$

verschlüsselt. Dabei sind

$x_i = u_i, 1 \leq i \leq k$ die **Nachrichtenziffern** und

$$x_{k+1} = \sum_{j=1}^k a_{ji} u_j, \quad 1 \leq i \leq n - k$$

sind **Korrekturziffern**. Letztere

induzieren Redundanz, die der Nachricht angehängen wurden, um Störungen auszugleichen.

Bsp. 1.4. Sei C der binäre $[7,4]$ -code mit Generatormatrix in Standardform

$$G = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 1 \\ 0 & 1 & 0 & 0 & 1 & 1 & 1 \\ 0 & 0 & 1 & 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 & 1 \end{bmatrix}.$$

Ein Nachrichtenvektor u wird kodiert durch:

$$uG = \begin{pmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_1 + u_2 + u_3 \\ u_2 + u_3 + u_4 \\ u_1 + u_2 + u_4 \end{pmatrix}$$


Beispielsweise gilt:

$$(0 \ 0 \ 0 \ 0) \rightarrow (0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0)$$

$$(1 \ 0 \ 0 \ 0) \rightarrow (1 \ 0 \ 0 \ 0 \ 1 \ 0 \ 1)$$

$$(1 \ 1 \ 0 \ 0) \rightarrow (1 \ 1 \ 1 \ 0 \ 1 \ 0 \ 0)$$

Bem. 1.5. Allg. gilt für einen linearen Code für den Verschlüsselungsprozess folgendes Kommunikationsschema:



2. Entschlüsseln eines linearen Codes

Def. 2.1. Sei $x = x_1 \dots x_n$ ein Codewort, das durch den Kanal gesendet wird und als $y = y_1 \dots y_n$ ankommt.

Wir definieren den **Fehlervektor** als $e := y - x = e_1 \dots e_n$.

Bem. 2.2. Der Entschlüssler hat nun zwei äquivalente Möglichkeiten:

- i) Anhand von y erkennen, welches Codewort x übermittelt wurde
- ii) Erkennen welcher Fehlervektor e entstanden ist.

Def 2.3. Sei C ein $[n, k]$ -code über $GF(q)$ und $a \in V(n, q)$. Dann heißt

$$a + C = \{a + x \mid x \in C\}$$

Nebenklasse von C .

Lemma 2.4. Sei $a + C$ eine Nebenklasse von C und $b \in a + C$. Dann:

$$b + C = a + C$$

Bew.: Da $b \in a + C$ gilt $b = a + x$ für gewisses $x \in C$. Sei nun $b + y \in b + C$. Dann:

$$\begin{aligned} b + y &= (a + x) + y \\ &= a + (x + y) \in a + C \end{aligned}$$

also $b + C \subseteq a + C$.

Sei nun $a + z \in a + C$. Dann:

$$\begin{aligned} a + z &= (b - x) + z \\ &= b + (z - x) \in b + C \end{aligned}$$

also $a + C \subseteq b + C$.

Insg. folgt $a + C = b + C$ $\square$

Theorem 2.5. Sei C ein $[n, k]$ -code über $GF(q)$.

Dann:

- i) Jeder Vektor aus $V(q, n)$ ist in einer Nebenklasse von C enthalten.
- ii) Jede Nebenklasse enthält genau q^k Vektoren.
- iii) Zwei Nebenklassen sind entweder

disjunkt oder identisch.

Bew.: i) Falls $a \in V(n, q)$, dann:

$$a = a + 0 \in a + C$$

ii) Die Zuordnung von C nach $a + C$ def. durch
 $x \rightarrow a + x \quad \forall x \in C$ ist offensichtlich injektiv, daher:

$$|a + C| = |C| = q^k$$

iii) Angenommen die Nebenklassen $a + C$ und $b + C$ überschneiden sich. Dann ex. ein Vektor v mit

$$v \in (a + C) \cap (b + C).$$

Daher gilt für gewisse $x, y \in C$:

$$v = a + x = b + y.$$

Dann $b = a + (x - y) \in a + C$
und nach Lemma 2.4

$$a + C = b + C. \quad \square$$

Bsp. 2.6. Sei C der binäre $[4, 2]$ -code mit Generatormatrix

$$G = \begin{bmatrix} 1 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{bmatrix}$$

z.B. $C = \{0000, 1011, 0101, 1110\}$.

Dann sind die Nebenklassen von C :

$$0000 + C = C$$

$$1000 + C = \{1000, 0011, 1101, 0110\}$$

$$0100 + C = \{0100, 1111, 0001, 1010\}$$

$$0010 + C = \{0010, 1001, 0111, 1100\}$$

Achtung:

$$\text{Für } 0001 + C = \{0001, 1010, 0100, 1111\}$$

gilt $0001 + C = 0100 + C$. Das hätte man auch hervorsagen können, denn $0001 \in 0100 + C$.

Def. 2.7. Der Vektor mit minimalem Gewicht (wdh. Gewicht $w(x) \cong$ Anzahl der Einträge in $x \neq 0$) einer Nebenklasse heißt **Nebenklassenanhänger**.

Bem. 2.8. Falls mehrere Vektoren minimales Gewicht haben, so suchen wir uns einen bel. aus und bezeichnen ihn als Nebenklassenanhänger.

Bem. 2.9. Wegen Theorem 2.5. gilt, dass $V(n, q)$ in disjunkte Nebenklassen von C zerlegt werden kann:

$$V(n, q) = (0 + C) \cup (a_1 + C) \cup \dots \cup (a_s + C)$$

mit $s = q^{n-k} - 1$. Nach Lemma 2.4.

können wir $0, a_1, \dots, a_s$ als Nebenklassenanhänger setzen.

Def. 2.10. Ein **standardarray** für einen $[n, k]$ -code C ist ein $q^{n-k} \times q^k$ -array mit allen Vektoren in $V(n, q)$, in denen die erste Reihe aus dem Code C mit 0 ganz außen links besteht und die restlichen Reihen sind die Nebenklassen $a_i + C$, wobei diese alle in korrespondierender Reihenfolge mit dem Nebenklassenanhänger links angeordnet sind.

Algo. 2.11 Schritt 1: Erstelle eine Liste aus den Codewörtern von C , beginnend mit 0 als erste Reihe.

Schritt 2: Wähle bel. Vektor $a_1 \notin (0 + C)$ mit minimalem Gewicht. Setze die Nebenklasse $a_1 + C$ als zweite Reihe, indem man 0 unter a_1 und

$a_1 + x$ unter $x \forall x \in C$ setzt.

Schritt 3: Aus den Vektoren, die nicht in den vorherigen Reihen enthalten sind, wählt man ein bel. a_2 mit minimalem Gewicht und ordnet die Nebenklasse $a_2 + C$ wie in Schritt 2 beschrieben an.

Schritt 4: Wiederhole dieses Vorgehen bis alle Nebenklassen sortiert sind und jeder Vektor aus $V(n, q)$ genau einmal auftaucht.

Bsp. 2.12. Ein Standardarray für den Code aus Bsp. 2.6. ist

Codewörter {

0000	1011	0101	1110
1000	+ 0011	1101	0110
0100	1111	0001	1010
0010	1001	0111	1100

Nebenklassenführer

Bem. 2.13. In einem Standardarray ist jeder Eintrag die Summe aus dem Codewort der Zeile darunter und dem Nebenklassenführer dieser.

Bem. 2.14. Der Entschlüssler nutzt den Standardarray wie folgt:
Wenn z.B. $y = 1111$ ankommt, wird dessen Position im array bestimmt. Dann entscheidet der Entschlüssler, dass der Fehlervektor e der Nebenklassenanführer 0100 ist, den man ganz links von y findet. Nun ist y entschlüsselt als das Codewort $x = y - e = 1011$.
Kurz gesagt: Man entschlüsselt einen Vektor als das Codewort über der Spalte, die y enthält.

Bem. 2.15. Die Fehlervektoren, die korrigiert werden, sind gerade die Nebenklassenanführer, unabhängig davon, welches Codewort übermittelt wird. Indem man einen Vektor von minimalem Gewicht in jeder Nebenkasse als Nebenklassenanführer wählt, stellen wir sicher, dass der Standardarray, den wir zum entschlüsseln nutzen, ein „Nächster-

Nachbar-Schema" ist.

Bsp. 2.16. In Bsp. 2.12 wird ein einfacher Fehler nur korrigiert, wenn er in den ersten drei Stellen auftaucht, nicht aber in der vierten Stelle.

Nachricht	Codewort	Kanal + Störung	erh. Vektor	entschl. Wort	erh. Nachricht
01	→ 0101	→ 0101	→ 0001	→ 0101	→ 01
01	→ 0101	→ 0101	→ 0100	→ 0000	→ 00

Bem. 2.17. Im zweiten Fall sehen wir, dass Kanal und Störung das Codewort nicht beeinflusst haben, wir aber trotzdem die falsche Nachricht 00 erhalten haben. In diesem Fall hat das Anhängen der Redundanz mehr Schaden angerichtet, als nützlich zu sein.

Um aber eine sinnvolle Bewertung für einen „guten Code“ zu bekommen, müssen wir die **Wahrscheinlichkeit** kennen mit der ein erhaltener Vektor mittels dem Standardarray korrekt entschlüsselt wird.

3. Die Wahrscheinlichkeit einer Fehlerkorrektur

Bem. 3.1. Der Einfachkeits halber begrenzen wir uns in diesem Kapitel auf binäre lineare Codes. Wir nehmen an, dass der Kanal binär symmetrisch mit Zeichenfehlerwahrscheinlichkeit p verteilt ist. In einer vorherigen Sitzung haben wir festgehalten, dass die Wahrscheinlichkeit, dass der Fehlervektor ein gegebener Vektor mit Gewicht i ist, $p^i (1-p)^{n-i}$ beträgt ($\Rightarrow$ Binomialverteilung).

Theorem 3.2. Sei C ein binärer $[n, k]$ -code.

Für $i = 0, \dots, n$ sei α_i die Anzahl der Nebenklassenanführer mit Gewicht i . Dann beträgt die Wahrscheinlichkeit, dass ein erhaltener Vektor, der mit einem Standardarray entschlüsselt wurde, korrekt ist

$$P_{\text{corr}}(c) := \sum_{i=0}^n \alpha_i p^i (1-p)^{n-i}.$$

Bsp. 3.6. Für den $[4, 2]$ -code aus Bsp. 2.16. sind die Nebenklassenanführer 0000, 1000, 0100, 0010. Daher gilt $\alpha_0 = 1, \alpha_1 = 3, \alpha_2 = \alpha_3 = \alpha_4 = 0$ und für $P_{corr}(c)$:

$$P_{corr}(c) = (1 - p)^4 + 3p(1 - p)^3$$


Bem. 3.7. Die Wahrscheinlichkeit, dass ein entschlüsseltes Wort nicht dem gesendeten Wort entspricht heißt **Wort-Fehler-Rate** und es gilt:

$$P_{err}(C) = 1 - P_{corr}(C)$$

Bem. 3.8. Ein linearer $[n, k]$ -code C nutzt n Zeichen um k Nachrichten zu senden. Man sagt dieser Code hat eine **Rate** von $R(c) = \frac{k}{n}$. Ein "guter Code" wird eine hohe Rate haben.

Def. 3.9 Die **Kapazität** $\varphi(p)$ eines binären symmetrischen Kanals mit Zeichenfehlerwahrscheinlichkeit p ist

$$\varphi(p) = 1 + p \log(p) + (1 - p) \log(1 - p)$$



Theorem 3.10. Gegeben sei ein binärer symmetrischer Kanal mit Zeichenfehlerwahrscheinlichkeit p . Sei $R < \varphi(p)$. Dann:

$\forall \varepsilon > 0 \exists [n, k]$ -code C mit n hinreichend groß und $\frac{k}{n} > R$:
 $P_{err}(C) < \varepsilon$.

Bsp. 3.11. Es gilt: $\varphi(0.01) \cong 0.92$. D.h. für $p = 0.01$ können wir selbst, wenn wir auf eine Rate von $\frac{9}{10}$ bestehen würden, theoretisch P_{err} so klein bekommen wie wir möchten, indem wir n und k hinreichend groß wählen.