


Kapitel 11: Binäre Kanäle



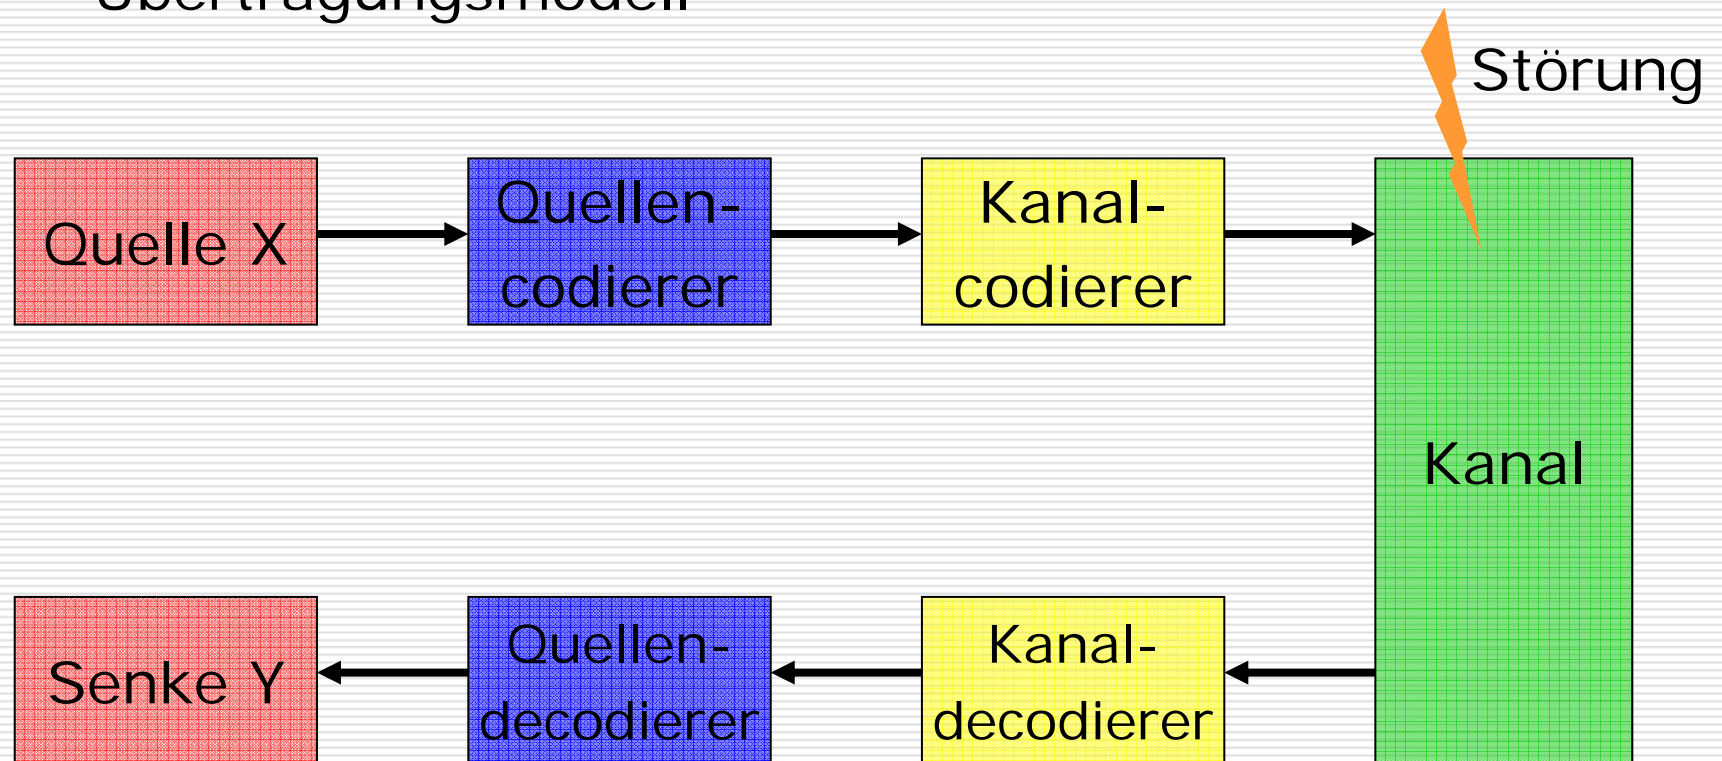
Ziele des Kapitels

- ❑ Binäre Kanäle und ihre Eigenschaften
- ❑ Gedächtnisfreie Kanäle
- ❑ Codierung als Schätzung und Schätzverfahren
- ❑ Kanalkapazität
- ❑ Shannon'sches Kanalcodierungstheorem

- ❑ Reale Übertragungskanäle sind meist fehlerbehaftet
- ❑ „Rohe“ Bits oft als analoge Signale (Spannungspegel) empfangen
- ❑ Störungen führen zu Fehlklassifikationen
- ❑ Redundante Codierung ermöglicht eine gewisse Fehlertoleranz
- ❑ **Quellencodierer** versuchen, einen fehlerfreien Input optimal zu codieren
- ❑ **Kanalcodierer** bringen gezielt Redundanz (Prüfbits) in den Code ein


Übertragungsmodell

- Wir betrachten wieder das folgende Übertragungsmodell



- ❑ Eine Variante ist, Fehler zu detektieren und das Zeichen nochmals zu übertragen
- ❑ Sinnvoll bei kleinen Fehlerwahrscheinlichkeiten
- ❑ Anspruchsvollere Variante: Fehler detektieren und beim Empfänger korrigieren
- ❑ Dazu müssen **Fehlerkorrekturverfahren** entwickelt werden
- ❑ Sehr grosse praktische Bedeutung (Speichermedien, Netzwerkübertragung etc.)
- ❑ Grundlegendes Modell: Allgemeiner **Binärer Kanal (BK)**

- Der binäre Kanal



- Seien $p(x_0)$ und $p(x_1)$ die Wahrscheinlichkeiten für die Symbole $\{0,1\}$ am Kanaleingang
- Ebenso seien $p(y_0)$ und $p(y_1)$ die Wahrscheinlichkeiten am Kanalausgang
- Dann gilt

$$\begin{pmatrix} p(y_0) \\ p(y_1) \end{pmatrix} = \begin{pmatrix} 1-\varepsilon & \delta \\ \varepsilon & 1-\delta \end{pmatrix} \begin{pmatrix} p(x_0) \\ p(x_1) \end{pmatrix}$$

wobei

$$p(y_j | x_i) \Leftrightarrow \begin{pmatrix} 1-\varepsilon & \delta \\ \varepsilon & 1-\delta \end{pmatrix}$$

die Matrix der Übergangswahrscheinlichkeiten ist

- **Definition:** Die **Transinformation** H_T ist die pro Kanalzeichen übertragene Information
- Für den binären Kanal ergibt sie sich wie folgt:

$$H_T = I(X;Y) = H(Y) - H(Y | X)$$

mit

$$H(Y) = - \sum_{j \in \{0,1\}} p(y_j) \log_2 p(y_j)$$

und

$$H(Y | X) = - \sum_{i \in \{0,1\}} p(x_i) \sum_{j \in \{0,1\}} p(y_j | x_i) \log_2 p(y_j | x_i)$$

- Gegeben: $p(x_0)=0.2$, $p(x_1)=0.8$, $\delta=0.1$ und $\varepsilon=0.001$
- Gesucht H_T

$$p(y_j | x_i) = \begin{pmatrix} 0.999 & 0.1 \\ 0.001 & 0.9 \end{pmatrix} \quad \begin{aligned} p(y_0) &= 0.999 \cdot 0.2 + 0.1 \cdot 0.8 = 0.280 \\ p(y_1) &= 0.001 \cdot 0.2 + 0.9 \cdot 0.8 = 0.720 \end{aligned}$$


$$H(Y) = 0.855 \text{ Bit/QZ}$$

$$\begin{aligned} H(Y | X) &= -0.2 \cdot (0.999 \cdot \log_2 0.999 + 0.001 \cdot \log_2 0.001) \\ &\quad - 0.8 \cdot (0.9 \cdot \log_2 0.9 + 0.1 \cdot \log_2 0.1) \\ &= 0.377 \text{ Bit/QZ} \end{aligned}$$

$$H_T = H(Y) - H(Y | X) = 0.478 \text{ Bit/QZ}$$

Spezialfall 1

- Der binäre, **symmetrische** Kanal (BSK)



- ❑ Jedes Bit wird mit einer Wahrscheinlichkeit ε bei der Übertragung invertiert (verfälscht)
- ❑ Bei $\varepsilon=0$ kann 1 bit Information pro Kanalnutzung zuverlässig übertragen werden
- ❑ Bei $\varepsilon=0.5$ wird die Ausgabe-Bitfolge gleichverteilt und statistisch unabhängig von der Eingabe
- ❑ Es wird keine Information übertragen
- ❑ Die **Kapazität** des Kanals ist 1 bit/Nutzung ($\varepsilon=0$) und 0 bit/Nutzung ($\varepsilon=0.5$)

$$H_T = H(Y) + (1 - \varepsilon) \log_2(1 - \varepsilon) + \varepsilon \log_2 \varepsilon$$

- ❑ $\varepsilon=1$ ist gleichwertig zu $\varepsilon=0$
- ❑ Für $0 < \varepsilon < 0.5$ kann eine beliebig zuverlässige Übertragung erreicht werden, wenn jedes Bit genügend oft gesendet wird
- ❑ Mehrheitsentscheidung am Kanalausgang notwendig
- ❑ Mit zunehmender Redundanz nimmt hierbei jedoch die Übertragungsrate ab
- ❑ Durch geschickte Codierung kann die Fehlerwahrscheinlichkeit bei **gleichbleibender** Rate beliebig verkleinert werden

- ❑ Shannon zeigte, dass die Übertragungsrates in Grenzen **unabhängig** von der Übertragungskapazität ist
- ❑ Jeder Kanal besitzt eine **Kapazität**
- ❑ Diese ist die maximale Rate, mit der Information zuverlässig übertragbar ist
- ❑ Die dazu nötigen Codes können entsprechend komplex werden




Dies ist ein zweites, fundamentales Gesetz von Claude Shannon und in seinem (zweiten) Kanalcodierungstheorem zusammengefasst

- Generell wird ein Kanal durch die Übergangsmatrix zwischen Eingang und Ausgang definiert
- Eine bedeutende Unterklasse sind sogenannte **gedächtnisfreie** Kanäle
- Hierbei ist der Output Y_i nur vom aktuellen Input X_i abhängig, nicht von seiner Vorgeschichte $X_{i-1} \dots X_1$
- **Definition:** Ein diskreter, **gedächtnisfreier** Kanal (DGK) für ein Inputalphabet χ und ein Outputalphabet γ ist eine bedingte Verteilung

$$P_{Y|X} : \gamma \times \chi \rightarrow R^+$$

Spezialfall 2

- Der binäre, Auslöschungskanal (BAK)
- Keine Bitinversion, nur Auslöschung




- **Definition:** Ein Blockcode C mit Blocklänge N für einen Kanal mit Inputalphabet χ ist eine Teilmenge $C = \{c_1, \dots, c_M\}$ von χ^N der N -Tupel über χ . Die Rate R von C ist

$$R = \frac{\log_2 M}{N}.$$


- R ist die Anzahl der Bits, die pro Kanalnutzung gesendet werden können

Decodierung als Schätzung

- ❑ Die Decodierung einer fehlerbehafteten Zeichenfolge, gegeben die Symbolfolge am Kanalausgang kann als (Parameter)-**Schätzproblem** betrachtet werden
- ❑ Wir bedienen uns hierzu allgemeiner, statistischer Schätzmethoden
- ❑ Es sei U dabei eine Zufallsvariable, die aufgrund einer Beobachtung V geschätzt werden soll
- ❑ Die Wahrscheinlichkeitsverteilung $P_{V|U}$ sei bekannt



Wir erinnern uns an das Informationstheorie-Lemma, welches besagt, dass wir durch Berechnung KEINE Information hinzufügen können.



- Der **Schätzer** ist eine Funktion f , welche jedem Wert v der Beobachtung den entsprechenden Schätzwert \tilde{u} zuordnet

- Die Schätzung ist **optimal**, wenn die Wahrscheinlichkeit einer korrekten Schätzung $P(U=\tilde{U})$ maximiert wird

$$P(U = \tilde{U}) = \sum_v P(U = \tilde{U}, V = v) \rightarrow \max$$

- Wir schreiben

$$P(U = \tilde{U}) = \sum_v P_{UV}(f(v), v) = \sum_v P_{V|U}(v, f(v))P_U(f(v))$$

- Dieser Ausdruck soll durch Wahl von f maximiert werden

- ❑ **Fall 1:** P_U bekannt (prior bekannt): In diesem Fall muss für jedes v dasjenige \tilde{u} für $f(v)$ gewählt werden, damit

$$P_{V|U}(v, \tilde{u})P_U(\tilde{u}) \rightarrow \max$$

- ❑ Dies wird auch als **minimum-error** estimation (ME) bezeichnet
- ❑ **Fall 2:** P_U nicht bekannt (uniform prior): Man nimmt an, dass alle Werte von U gleichwahrscheinlich sind
- ❑ Da $P_U(u)$ für alle u gleich ist, muss es bei der Maximierung nicht beachtet werden

Decodierung als Schätzung

- In diesem Fall muss für jedes v dasjenige \tilde{u} für $f(v)$ gewählt werden, damit

$$P_{V|U}(v, \tilde{u}) \rightarrow \max$$

- Dies wird auch als **maximum likelihood** estimation (ML) bezeichnet



Diese beiden Schätzverfahren sind universell und werden in vielen Anwendungen der Natur- und Ingenieurwissenschaften ausgiebig eingesetzt.

In der Praxis dominiert oft die ML-Methode, da der Prior oft nicht bekannt ist.

- Wenn das Codewort $c_j = [c_{j1}, \dots, c_{jN}]$ über einen DGK mit Übergangsverteilung $P_{Y|X}$ gesendet wird, so ist der Kanaloutput eine Zufallsvariable $Y^N = [Y_1, \dots, Y_N]$ mit Wertmenge γ^N und Verteilung

$$P_{Y^N|X^N}(y^N, c_j) = \prod_{i=1}^N P_{Y|X}(y_i, c_{ji})$$

- Im Decoder muss also für ein empfangenes Kanaloutputwort

$$y^N = [y_1, \dots, y_N]$$

die beste Schätzung für das gesendete Codewort finden

Decodierung als Schätzung

- Dieser Schätzvorgang heisst Decodierung
- Mit den Entsprechungen

$$U = X^N \quad V = Y^N$$

erhalten wir die folgenden Theoreme

- Es sei \tilde{U} die Schätzung des Coders

- Ein Decoder, der für ein gegebenes Empfangswort y^N als Schätzung des gesendeten Codewortes eines derjenigen $c_j = [c_{j1}, \dots, c_{jN}]$ wählt, welches

$$P_{Y^N|X^N}(y^N, c_j) P_{X^N}(c_j) \rightarrow \max$$

erreicht die minimale Fehlerwahrscheinlichkeit

- Nachteil ist hierbei, dass die Verteilung der Codewörter bekannt sein muss
- In der Praxis ist die Quellenstatistik oft nicht bekannt

Maximum Likelihood Decoder **ETH**

- Ein Decoder, der für ein gegebenes Empfangswort y^N als Schätzung des gesendeten Codewortes eines derjenigen $c_j = [c_{j1}, \dots, c_{jN}]$ wählt, welches


$$P_{Y^N|X^N}(y^N, c_j) \rightarrow \max$$

erreicht die minimale Fehlerwahrscheinlichkeit, wenn alle Codewörter gleichwahrscheinlich sind

- Ein DGK ist durch die bedingte Wahrscheinlichkeitsverteilung $P_{Y|X}$ eindeutig beschrieben
- Die Inputverteilung P_X ist jedoch frei
- Wir wählen sie so, dass maximal viel Information übertragen wird
- **Definition:** Die **Kapazität** eines durch $P_{Y|X}$ charakterisierten DGK ist das Maximum über Inputverteilungen P_X von $I(X; Y)$

$$C = \max_{P_X} I(X; Y) = \max_{P_X} [H(Y) - H(Y | X)]$$

- ❑ Wir werden zeigen, dass die Kapazität eine **obere Grenze** für die Rate darstellt, mit der Information zuverlässig übertragen werden kann
- ❑ Im Allgemeinen sind Kapazitätsberechnungen eher schwierig
- ❑ Wir suchen eine Inputverteilung P_X , die $H(Y)$ maximiert und $H(Y/X)$ minimiert



Die Kanalkapazität ist also das Maximum der Transinformation des Kanals

- Die Berechnung vereinfacht sich für folgende Bedingungen

- A) $H(Y|X=x)$ ist für alle x gleich, also

$$H(Y | X = x) = t$$

- B) Die folgende Summe ist für alle y gleich

$$\sum_x P_{Y|X}(y, x) = s$$

- Letzteres bewirkt, dass bei Gleichverteilung am Kanaleingang auch Gleichverteilung am Kanalausgang vorliegt

- **Theorem:** Die Kapazität eines Kanals, welcher die Bedingungen A) und B) erfüllt, ist

$$C = \log|\gamma| - t$$

- Wir betrachten den BSK als Beispiel

$$H_T = H(Y) + (1 - \varepsilon) \log_2(1 - \varepsilon) + \varepsilon \log_2 \varepsilon$$

- Übertragungsmatrix:

$$\begin{pmatrix} p(y_0) \\ p(y_1) \end{pmatrix} = \begin{pmatrix} 1-\varepsilon & \varepsilon \\ \varepsilon & 1-\varepsilon \end{pmatrix} \begin{pmatrix} p(x_0) \\ p(x_1) \end{pmatrix}$$

- Bedingung A:

$$\begin{aligned} H(Y | X = x_0) &= -p(y_0 | x_0) \cdot \log_2 p(y_0 | x_0) \\ &\quad - p(y_1 | x_0) \cdot \log_2 p(y_1 | x_0) \\ &= -(1-\varepsilon) \cdot \log_2(1-\varepsilon) - \varepsilon \cdot \log_2 \varepsilon \end{aligned}$$

$$\begin{aligned} H(Y | X = x_1) &= -p(y_0 | x_1) \cdot \log_2 p(y_0 | x_1) \\ &\quad - p(y_1 | x_1) \cdot \log_2 p(y_1 | x_1) \\ &= -\varepsilon \cdot \log_2 \varepsilon - (1-\varepsilon) \cdot \log_2(1-\varepsilon) \end{aligned}$$

- Bedingung B:

$$\sum_x P_{Y|X}(y, x) \text{ ist gleich für alle } y$$

→ Zeilensumme der Übergangsmatrix

- Berechnung der Kapazität:

$$\text{Es gilt: } p(y_0) = 1 - p(y_1)$$

$$\text{Transinformation: } H_T = H(Y) + \varepsilon \cdot \log_2 \varepsilon + (1 - \varepsilon) \cdot \log_2 (1 - \varepsilon)$$

$$\text{Kapazität: } C = \max H_T$$

$$\text{gemäss Formel } = \log_2 |\gamma| - t \text{ mit } t = \varepsilon \cdot \log_2 \varepsilon + (1 - \varepsilon) \cdot \log_2 (1 - \varepsilon)$$

$$\rightarrow \text{eingesetzt} = 1 + \varepsilon \cdot \log_2 \varepsilon + (1 - \varepsilon) \cdot \log_2 (1 - \varepsilon)$$

- Inputverteilung:

$$\max H(Y) = \max(p(y_0) \cdot \log_2 p(y_0) + p(y_1) \cdot \log_2 p(y_1))$$

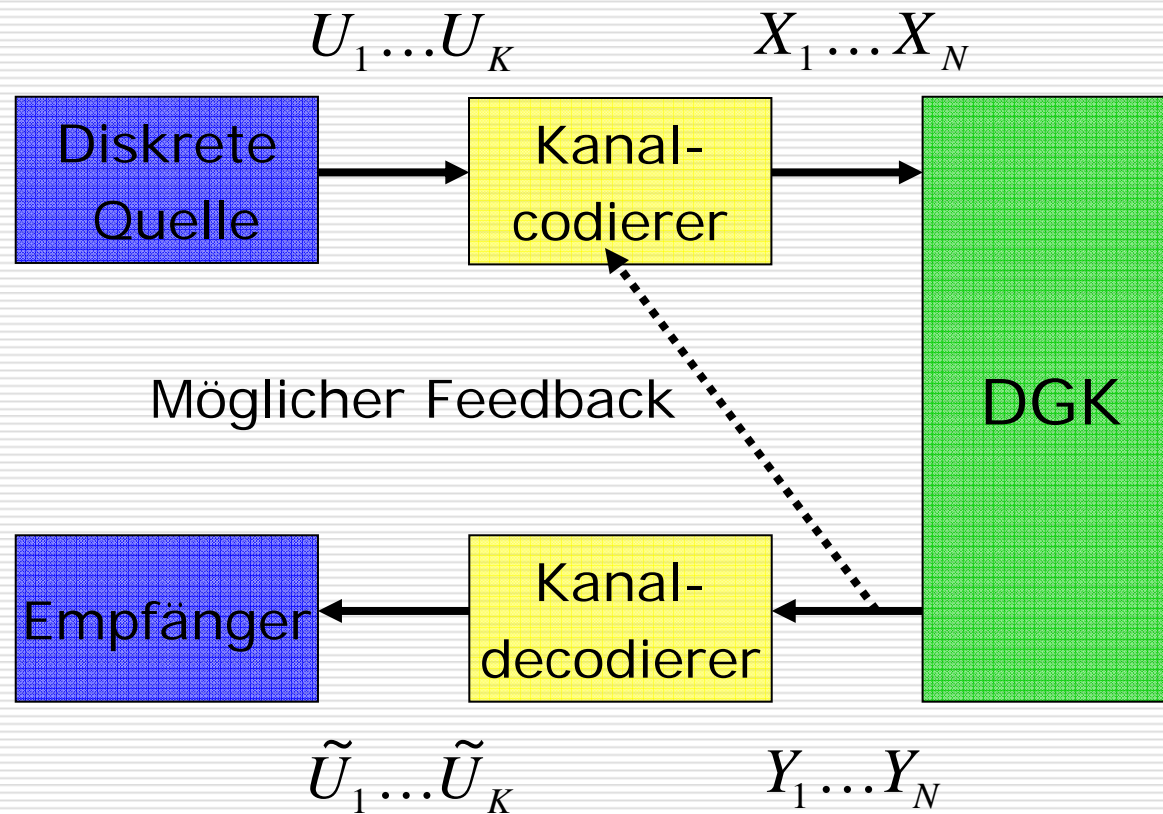
erreicht bei $p(y_0) = p(y_1) = \frac{1}{2}$ (Gleichverteilung)

$$p(y_0) = (1 - \varepsilon) \cdot p(x_0) + \varepsilon \cdot p(x_1)$$

$$p(y_1) = \varepsilon \cdot p(x_0) + (1 - \varepsilon) \cdot p(x_1)$$

$$\rightarrow p(x_0) = p(x_1) = \frac{1}{2}$$

- Die Kapazität ist eine Obergrenze für die Rate, mit der Information zuverlässig übertragen werden kann
- Je höher die Rate über der Kapazität, umso grösser die Fehlerwahrscheinlichkeit
- Wir betrachten das Modell eines DGK
- Es sollen K Informationsbits $U^K = [U_1, \dots, U_K]$ durch N Benutzungen übertragen werden
- Die Kapazität sei C
- Der Codierer übersetzt die Informationsbits in ein Codewort $X^N = [X_1, \dots, X_N]$, welches vom Kanal in $Y^N = [Y_1, \dots, Y_N]$ verfälscht wird



- Die Rate R ist demnach

$$R = \frac{K}{N} \text{ bits pro Nutzung}$$

- Der Decoder schätzt nun $[\tilde{U}_1, \dots, \tilde{U}_K]$
- Ein möglicher Feedback kann Information an den Decoder zurückliefern
- Man kann zeigen (Skript), dass

$$H(U^K | \tilde{U}^K) \geq H(U^K) - NC$$

- Die Kanalübertragung kann die Unsicherheit beim Empfänger nicht um mehr als NC reduzieren

- Damit U^K durch \tilde{U}^K bestimmt ist, muss die Anzahl der Kanalbenutzungen N mindestens sein:

$$N = \frac{H(U^K)}{C}$$