

Grundlagen Rechnernetze und Verteilte Systeme (IN0010)

Übungsblatt 11

18. Juni – 22. Juli 2022

Aufgabe 1 Kompression: Huffman-Kodierung

Gegeben sei das Alphabet $\mathcal{A} = \{a, b, c, d\}$ und die Nachricht

$$m = aabcdbdacababbbbcdbdbbbaababdbdbb \in \mathcal{A}^{32}.$$

a)* Bestimmen Sie die Auftrittswahrscheinlichkeiten $p_i \in \mathcal{A}$ der einzelnen Zeichen in m .

Aus den Zeichenhäufigkeiten ergibt sich:

$$p_a = \frac{8}{32} = \frac{1}{4}, p_b = \frac{16}{32} = \frac{1}{2}, p_c = \frac{3}{32} \approx 0,09, p_d = \frac{5}{32} \approx 0,16$$

b) Bestimmen Sie den Informationsgehalt $I(p_i)$ der einzelnen Zeichen aus \mathcal{A} .

Für den Informationsgehalt erhalten wir:

$$I(p_a) = -\log_2(p_a) = 2 \text{ bit}$$
$$I(p_b) = -\log_2(p_b) = 1 \text{ bit}$$
$$I(p_c) = -\log_2(p_c) \approx 3,42 \text{ bit}$$
$$I(p_d) = -\log_2(p_d) \approx 2,68 \text{ bit}$$

c) Die Nachricht m stamme aus einer Nachrichtenquelle X . Bestimmen Sie auf Basis der bisherigen Ergebnisse die Quellenentropie $H(X)$.

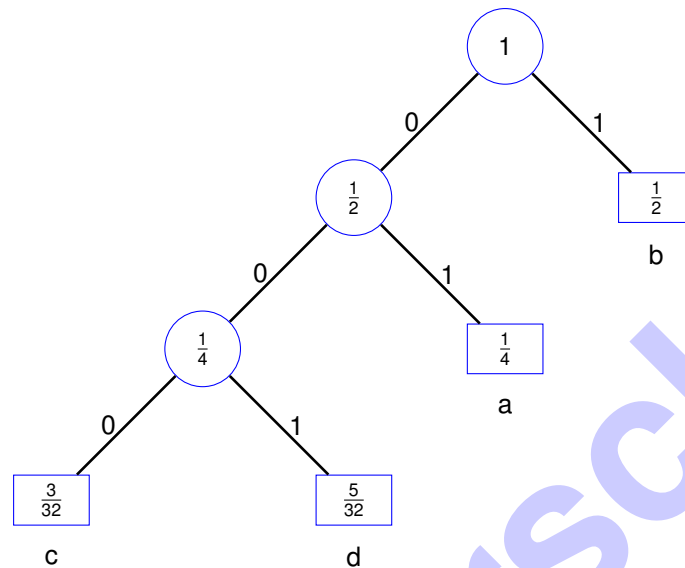
Die Quellenentropie ist nichts weiter als die mit den Auftrittswahrscheinlichkeiten gewichtete Summe des Informationsgehalts der Einzelzeichen:

$$H(X) = \sum_{i \in \mathcal{A}} p_i I(p_i) \approx 1,74 \text{ bit}$$

Dies bedeutet, dass sich die Zeichen der Quelle X mit durchschnittlich 1,74 bit pro Zeichen kodieren lassen.

d) Bestimmen Sie nun einen binären Huffman-Code C für diese Nachrichtenquelle.

Siehe Vorlesungsfolien. Beginnend bei den beiden Zeichen mit der geringsten Auftrittswahrscheinlichkeit wird ein Baum beginnend bei den Blättern (den Zeichen) konstruiert. Dabei werden in jedem Schritt stets die beiden Knoten bzw. Blätter zusammengefasst, so dass die Summe der Auftrittswahrscheinlichkeiten über alle Knoten bzw. Blätter minimal ist:



Die Kanten werden mit 0 bzw. 1 beschriftet. Der Code lässt sich nun einfach ablesen, indem man von der Wurzel ausgehend die Kantenbeschriftungen abliest: $C = \{a \mapsto 01, b \mapsto 1, c \mapsto 000, d \mapsto 001\}$

Zeichen mit hoher Auftrittswahrscheinlichkeiten erhalten kurze Codewörter. Außerdem lässt sich leicht überprüfen, dass C präfixfrei ist: Kein Codewort ist ein Präfix eines anderen Codeworts. Die Zeichen sind jeweils nur an den Blättern des Baums definiert, nicht jedoch an den inneren Knoten. Dies erleichtert die Dekodierung.

e) Bestimmen Sie die durchschnittliche Codewortlänge von C .

Die durchschnittliche Codewortlänge ergibt sich aus der mit den Auftrittswahrscheinlichkeiten gewichteten Summe der Codewortlängen. Sei $l(c)$ die Länge eines Codeworts in C und $c(i)$ die Funktion, welche ein Zeichen $i \in \mathcal{A}$ auf ein Codewort aus C abbildet. Dann erhalten wir:

$$\bar{l}_C = \sum_{i \in \mathcal{A}} p_i \cdot l(c(i)) = 1,75 \text{ bit}$$

f) Vergleichen Sie die durchschnittliche Codewortlänge von C mit der Codewortlänge eines uniformen¹ Binärcodes.

Der kürzeste uniforme Code hat eine durchschnittliche Codewortlänge von $\bar{l}_U = 2$. Die Ersparnis beträgt also etwa 12,5%.

¹Ein Code heißt *uniform*, wenn alle Codewörter dieselbe Länge aufweisen.

Aufgabe 2 Domain Name System (DNS)

Hinweis: Angelehnt an Endterm 2015


Zentrale Aufgabe des Domain Name Systems (DNS) ist es, menschenlesbare Namen auf IP-Adressen abzubilden, die dann für die Wegwahl auf der Netzwerkschicht verwendet werden können. Bei dem Namen `asciiart.grnvs.net.` handelt es sich um einen sog. *Fully Qualified Domain Name (FQDN)*.

a)* Was ist der Unterschied zwischen einem vollqualifizierten Domain Name (FQDN) und einem nicht (voll)qualifizierten?

Ein FQDN endet stets mit `.`, d. h. der Wurzel des Name Spaces. Ein nicht-qualifizierter Domain Name hingegen kann ein einzelnes Label oder eine geordnete Liste durch Punkte getrennter Labels sein, die relativ zu einer anderen Wurzel als `.` zu sehen sind.

b)* Benennen Sie die einzelnen Bestandteile des FQDNs, sofern es dafür gängige Bezeichnungen gibt.

1. Root (Beginn des Namensraums)
2. Top Level Domain (TLD)
3. Second Level Domain



Da im Alltag zumeist nicht explizit zwischen einem „FQDN“ (also mit terminierendem Punkt) und „Domain Name“ (also ohne terminierendem Punkt) unterschieden wird, da es kontextabhängig klar ist, was von beiden gerade gemeint ist, werden wir im Folgenden auch nur noch dann den Root-Punkt setzen, wenn wir dies besonders hervorheben bzw. deutlich machen wollen.

In Abbildung 2.1 sind ein PC sowie eine Reihe von Servern dargestellt. Wir nehmen an, dass PC1 den Router als Resolver nutzt. Der Router wiederum nutzt einen Resolver von Google unter der IP-Adresse 8.8.8.8 zur Namensauflösung. Ferner nehmen wir an, dass der Google-Resolver gerade neu gestartet wurde (also insbesondere keine Resource Records gecached hat) und rekursive Namensauflösung anbietet. Die autoritativen Nameserver für die jeweiligen Zonen sind in Tabelle 2.1 gegeben.




Abbildung 2.1: Vorlage zu Aufgabe 2f)

Zone	autoritativer Nameserver
.	d.root-servers.net.
com., net.	a.gtld-servers.net.
google.com.	ns1.google.com.
grnvs.net.	bifrost.grnvs.net.

Tabelle 2.1: Zonen mit zugehörigen autoritativen Nameservern

c)* Erläutern Sie den Unterschied zwischen einem *Resolver* und einem *Nameserver*.

Nameserver sind autoritativ für eine oder mehrere Zonen („Bereiche“), d. h. sie besitzen eine gültige und aktuelle Kopie der gesamten Zone, für die sie autoritativ sind. Resolver hingegen extrahieren mittels einer Reihe iterativer Anfragen an die jeweils autoritativen Nameserver die benötigten Informationen aus dem DNS und geben diese an den anfragenden Client zurück. Resolver können Einträge für begrenzte Zeit cachen, so dass bei erneuter Anfrage derselben Resource Records der Prozess nicht wiederholt werden muss.

d)* Welche Funktion erfüllen d.root-servers.net und a.gtld-servers.net?

Der Root-Nameserver ist autoritativ für die Rootzone, d. h. er kennt die Nameserver, welche für die einzelnen TLDs verantwortlich sind, so z. B. a.gtld-servers.net als einen der autoritativen Nameserver für net-Domains. a.gtld-servers.net kennt wiederum die zuständigen Nameserver für alle Second-Level-Domains unterhalb der net-TLD.

e)* Erklären Sie den Unterschied zwischen iterativer und rekursiver Namensauflösung.

Rekursive Namensauflösung bedeutet, dass eine DNS-Anfrage an einen Resolver gestellt wird. Dieser wird das endgültige Ergebnis zurücksenden. Bei iterativer Auflösung hingegen werden schrittweise die autoritativen Nameserver der einzelnen Zonen angefragt.

f) Zeichnen Sie in Abbildung 2.1 alle DNS-Nachrichten (Requests / Responses) ein, die ausgetauscht werden, sobald PC1 auf `asciart.grnvs.net` zugreift. Nummerieren Sie die Nachrichten gemäß der Reihenfolge, in der sie zwischen den einzelnen Knoten ausgetauscht werden.

g)* Wie wird im DNS sichergestellt, dass kein bössartiger Nameserver Anfragen für andere Domänen beantwortet? (Wir gehen davon aus, dass keine Man-in-the-Middle-Angriffe möglich sind.)

Dies wird lediglich indirekt dadurch sichergestellt, dass während der iterativen Namensauflösung stets nur die jeweils autoritativen Nameserver kontaktiert werden. Sofern die

- Antwort des Rootservers zuverlässig war und
- die Antwort auf dem Weg vom Rootserver zum anfragenden Nameserver nicht modifiziert wurde

kann ein bössartiger Nameserver keine falschen Antworten liefern – eben da er nie gefragt wird. Selbstverständlich wird auf diese Weise nicht verhindert, dass DNS-Antworten mittels Man-in-the-Middle-Angriffen abgefangen und modifiziert werden können. Dagegen helfen lediglich kryptographische Verfahren, wie sie in der DNSSEC-Erweiterung zu finden sind (nicht in der Vorlesung behandelt).

b)* Stellen Sie mittels des Kommandozeilenprogramms dig (Linux / macOS) bzw. nslookup (Windows) fest, welche der in Abbildung 3.1 aufgelisteten Nameserver jeweils für die Zonen tum.de, in.tum.de, ei.tum.de, mw.tum.de und net.in.tum.de autoritativ sind.

Wichtig: Leider unterscheiden sich die Antworten, wenn sie beispielsweise aus Eduroam gestellt werden (was sie eigentlich nicht sollten). Es ist möglich, dass dies auch aus anderen Teilen des Universitätsnetzes geschieht. Grund scheint ein interessantes Setup der Rechnerbetriebsgruppe zu sein.

Damit Sie reproduzierbare Antworten erhalten, nutzen Sie am besten einen der Google-Resolver: dig @8.8.8.8 tum.de NS

dig tum.de NS ergibt beispielsweise:

```
root@svm0048:~# dig @8.8.8.8 NS tum.de

; <<>> DiG 9.9.5-9+deb8u6-Debian <<>> @8.8.8.8 NS tum.de
; (1 server found)
;; global options: +cmd
;; Got answer:
;; ->>HEADER<<- opcode: QUERY, status: NOERROR, id: 825
;; flags: qr rd ra ad; QUERY: 1, ANSWER: 3, AUTHORITY: 0, ADDITIONAL: 1

;; OPT PSEUDOSECTION:
;; EDNS: version: 0, flags:; udp: 512
;; QUESTION SECTION:
;tum.de.                IN          NS

;; ANSWER SECTION:
tum.de.                 12197      IN         NS        dns3.lrz.eu.
tum.de.                 12197      IN         NS        dns2.lrz.bayern.
tum.de.                 12197      IN         NS        dns1.lrz.de.

;; Query time: 28 msec
;; SERVER: 8.8.8.8#53(8.8.8.8)
;; WHEN: Sun Jul 03 14:46:12 CEST 2016
;; MSG SIZE rcvd: 112
```

Der Answer Section ist zu entnehmen, dass von den gegebenen Nameservern lediglich dns1.lrz.de. autoritativ ist. Die anderen beiden Nameserver sind (zur Minderung des Schreibaufwands) nicht Teil der Aufgabenstellung.

Weitere Anfragen ergeben:

	dns1.lrz.de.	dns2.lrz.de.	dns3.lrz.de.	deneb.dfn.de.
tum.de.	X			
in.tum.de.	X			X
ei.tum.de.	X			
mw.tum.de.	X	X	X	
net.in.tum.de.	X			

c) Zeichnen Sie in den Namespace (Lösung von Teilaufgabe a)) die Abfolge der DNS-Nachrichten ein, die entsteht, wenn der Resolver `google-public-dns-a.google.com` versucht, den FQDN `git.net.in.tum.de.` aufzulösen. Gehen Sie davon aus, dass dem Resolver aus vorherigen Anfragen bereits `dns1.lrz.de.` als autoritativer Nameserver für `tum.de.` bekannt ist.

Siehe Lösung von Teilaufgabe a):

- Im ersten Schritt wird sich der Resolver sicher an `dns1.lrz.de.` wenden, da er laut Angabe der einzige autoritative Nameserver für `tum.de.` ist.
- Da `dns1.lrz.de.` sowohl für `tum.de.` als auch für `net.in.tum.de.` autoritativ ist, wird keine Delegation an weitere Nameserver mehr stattfinden.
- Stattdessen erhält der Resolver in diesem Fall bereits von `dns1.lrz.de.` den A Record für `git.net.in.tum.de.`

Die in der Vorlesung bzw. den Programmieraufgaben verwendeten virtuellen Maschinen haben Adressen aus dem Subnetz `188.95.232.0/21`.

d)* Erläutern Sie, wie der IPv4-Adressbereich in den DNS Namespace eingebettet wird.

IPv4-Adressen werden oktett-weise in umgekehrter Reihenfolge als Labels interpretiert und unterhalb des FQDNs `in-addr.arpa.` gespeichert.

e) Ergänzen Sie Ihre Lösung von Teilaufgabe a) um die FQDNs der zugehörigen Reverse Lookup Zones.


f)* Stellen Sie fest, welche Nameserver autoritativ für die Reverse Lookup Zones dieses Adressbereichs sind.

```
# dig +noall +answer 232.95.188.in-addr.arpa. NS
232.95.188.in-addr.arpa. 258 IN NS nimbus.net.in.tum.de.
232.95.188.in-addr.arpa. 258 IN NS lucifer.net.in.tum.de.
232.95.188.in-addr.arpa. 258 IN NS dns2.net.in.tum.de.
232.95.188.in-addr.arpa. 258 IN NS dns3.net.in.tum.de.
```

Die Outputs sollten zeigen, dass vier autoritative Nameserver existieren. Löst man deren IP-Adressen auf, stellt man fest, dass es lediglich zwei DNS-Server sind: `lucifer.net.in.tum.de.` und `nimbus.net.in.tum.de.`

g)* Aus welchem Grund ist es im DNS nicht möglich, die 4 Subnetze `188.95.232.0/24`, `188.95.233.0/24`, `188.95.234.0/24` und `188.95.235.0/24` mit nur einer Reverse Lookup Zone abzubilden?

Die beiden Netze lassen sich zwar im IP-Adressraum zum Netz `188.95.234.0/23` zusammenfassen, allerdings ist das nicht auf den DNS Name Space übertragbar, da hier keine Subnetzmasken oder Präfixlängen gespeichert werden. Der DNS Namespace orientiert sich vielmehr an den Adressklassen. Die einzige Möglichkeit `235.95.188.in-addr.arpa.` weiter zu delegieren besteht darin, eine eigene Zone für jede einzelne Adresse innerhalb des /24 Subnetzes zu erzeugen – Aufwand.
Hinweis: RFC 2317 beschreibt eine Möglichkeit, diese Beschränkung zu umgehen. Diese ist jedoch auch nicht „einfacher“, als einfach eine Zone pro Adresse zu erzeugen...



Lösungsvorschlag