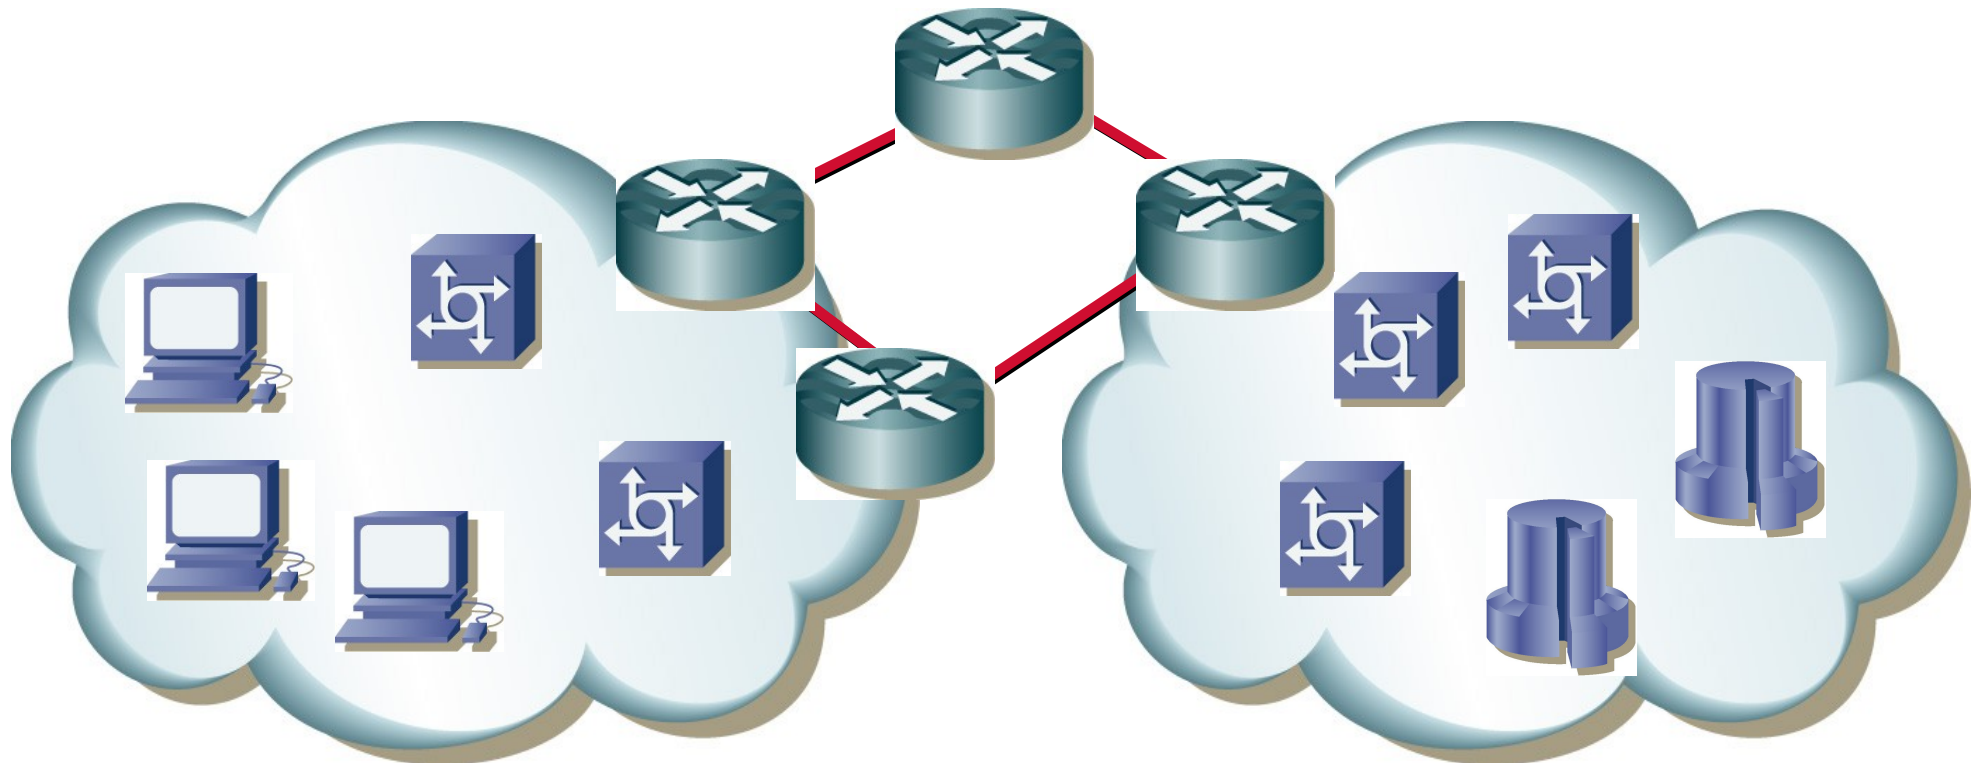


Počítačové sítě II

17. Elektronická pošta v Internetu

Miroslav Spousta, 2006

<qiq@ucw.cz>, <http://www.ucw.cz/~qiq/vsfs/>



Elektronická pošta

- služba, která slouží k výměně zpráv
- existuje mnoho standardů (firemních i veřejných)
- Internetová pošta (SMTP)
 - dnes asi nejrozšířenější
- MS Mail (Microsoft)
- X.400 (telekomunikační standard)
 - komplikované adresy typu G=Petr;S=Novak;O=cuni;OU=rektorat,C=cz
- přenos pomocí UUCP (Unix to Unix CoPy)
 - přenos souborů, zpráv před rozšířením Internetu
 - adresování pomocí vytyčení cesty k cíli přes propojené servery (hop)
 - např.: !{bighost,mail}!alpha!beta!novak
- jednotlivé systémy pro poštu zpravidla nejsou vzájemně kompatibilní 2

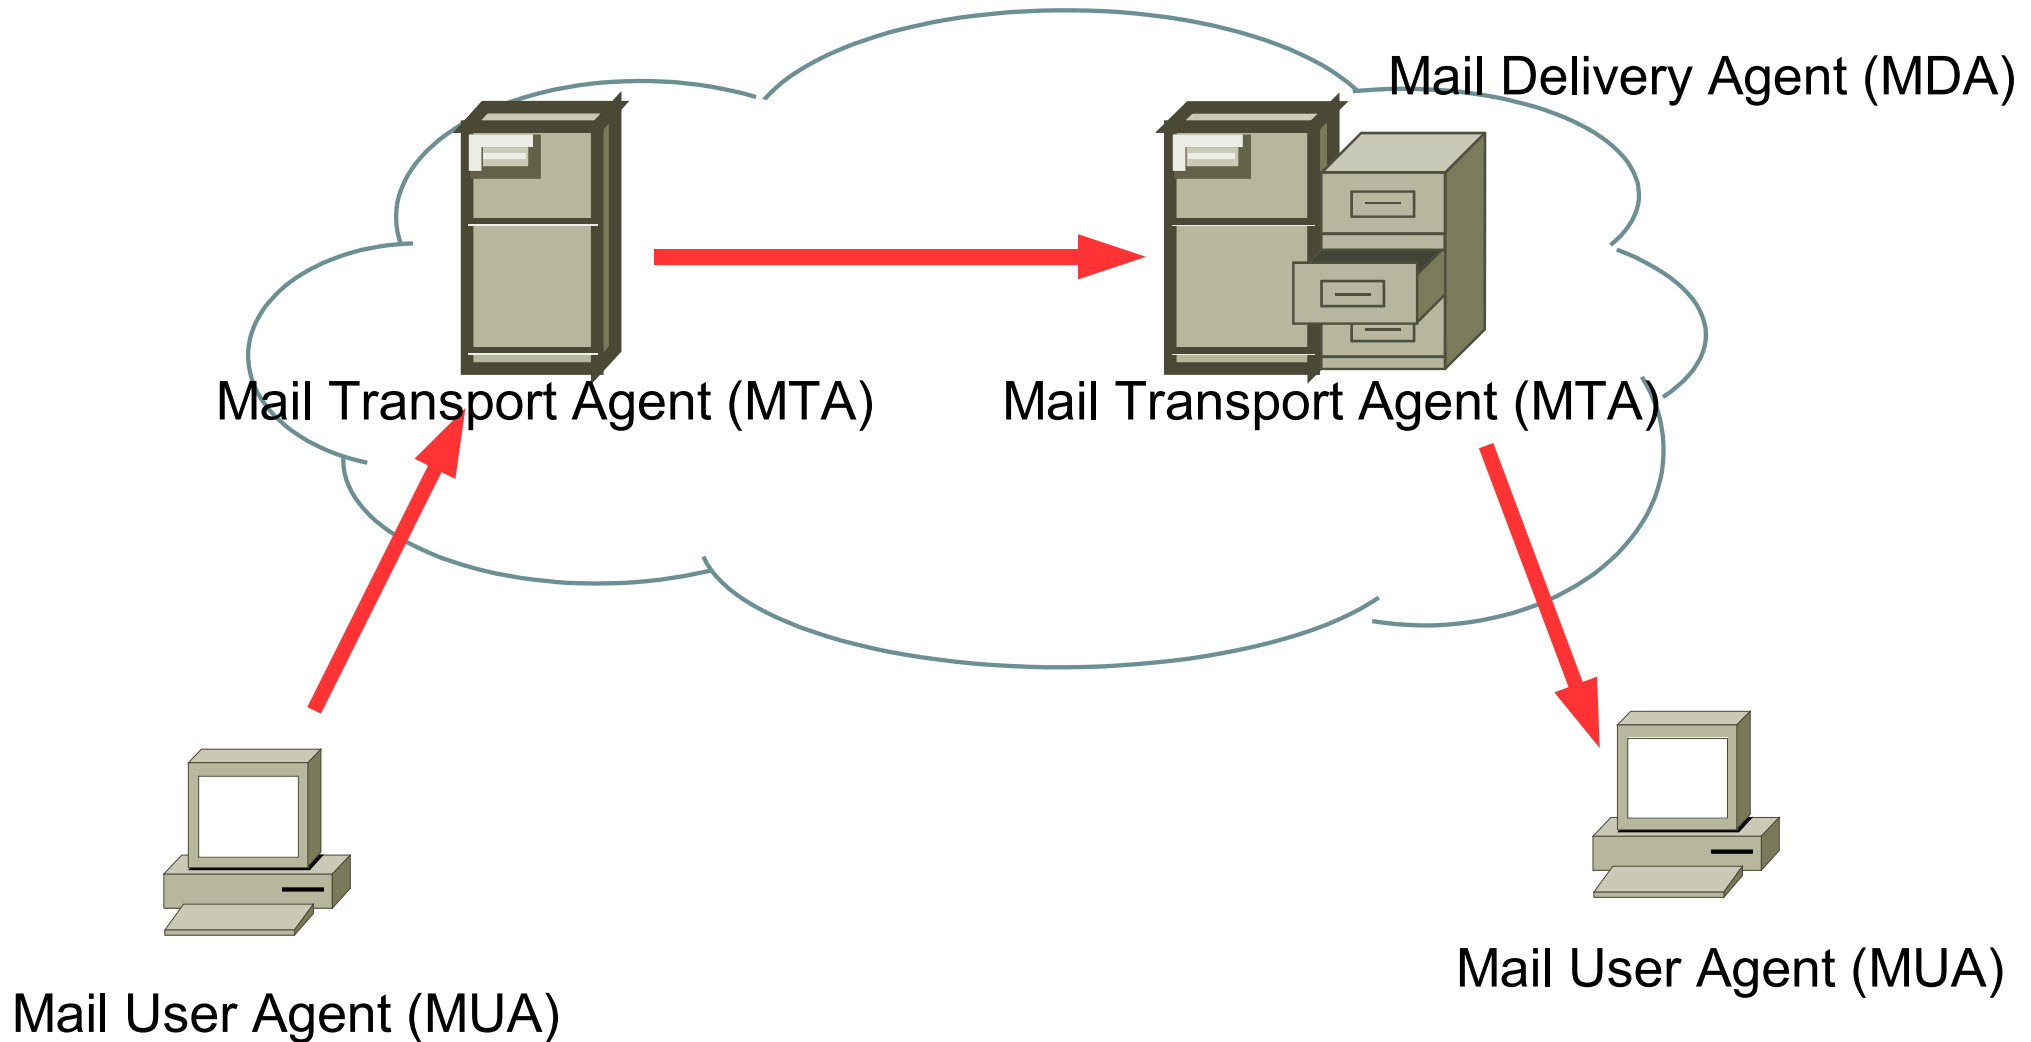
Elektronická pošta

- co musí definovat standard pro elektronickou poštu:
- formát zpráv
 - jak se bude zpráva dělit. kolik může mít částí
 - které údaje jsou povinné a které volitelné
- formát adres
 - v jakém formátu se bude zapisovat odesílatel a příjemce
- protokol pro přenos pošty mezi servery
 - jak si servery budou vyměňovat zprávy
- protokol pro poslání (submit) zprávy
- protokol pro získání zprávy
 - jak se klient dostane ke zprávám

Terminologie

- MUA = Mail User Agent
 - program, který běží na počítači uživatele
 - slouží pro interakci s uživatelem (psaní a čtení zpráv)
 - např. MS Outlook, Mozilla Thunderbird, The Bat!, ...
- MTA = Mail Transport Agent
 - je zodpovědný za doručování pošty od odesílatele k příjemci
 - většinou servery elektronické pošty po cestě
 - např. Sendmail, Postfix, Exim, MS Exchange
- MDA = Mail Delivery Agent
 - program, který poštu doručuje do schránky na cílovém serveru
 - např. procmail, maildrop, lmtpl (Unix), nebo součástí MTA (MS Exchange)
- poštovní schránka: pro každého uživatele, doručuje se do ní pošta

Terminologie



Elektronická pošta v Internetu

- v Internetu: SMTP (Simple Mail Transport Protocol)
 - použitelný i mimo Internet
 - používá spolehlivou službu (v Internetu TCP)
 - vznikl původně jako jednoduchý protokol pro přenos zpráv (co nejpodobnější reálnému světu)
 - RFC822 (RFC2822)
- SMTP služba je rychlá
 - doručování – sekundy až minuty
- SMTP služba je spolehlivá
 - komunikace je navrhovaná tak, aby nedošlo ke ztrátě zpráv při neočekávaných situacích (výpadcích spojení, elektrické energie, ...)
 - je dané, kdo je zodpovědný v každé chvíli za danou zprávu
- SMTP je efektivní
 - jednoduchý formát, umožňuje automatické hromadné zpracování

SMTP pošta

- původně pouze pro přenos textových (ASCII) zpráv
 - dnes i přílohy, národní znaky, zprávy skládající se z několika částí
- je jednoduchý (textový)
 - srozumitelný i člověku (testování)
 - ale dobře zpracovatelný automaticky
- funguje off-line
 - příjemce a odesílatel nemusí být ve stálém připojení
 - odesílatel zprávu pošle, ta se zařadí do fronty a počká, až ji bude možné doručit
 - příjemce vyzvedává svojí zprávu také nezávisle
- původně uživatel přistupoval k poště na stejném počítači, jako má umístěnu poštovní schránku
 - dneska většinou vzdálený přístup, resp. rozdělená poštovní schránka

RFC týkající se pošty

- RFC 822 (RFC 2822) definuje
 - formát zprávy
 - jak vypadá hlavička zprávy, z čeho se skládá
 - které položky jsou povinné, které volitelné
 - tělo zprávy
 - v jakém je formátu, jak je odděleno od hlavičky
- RFC 821 (RFC 2821) definuje
 - protokol pro přenos pošty mezi MTA: SMTP
 - zahájení a ukončení přenosu a doplňující příkazy
- RFC 2045 – 2049 (MIME)
 - rozšiřují možnosti pošty o posílání příloh
 - strukturování těla zprávy a ukládání binárních dat
 - umožňují používat národní jazyky v hlavičkách

Formát zprávy (RFC 822)

- zprávy jsou kódovány jako text (v US-ASCII)
 - konce řádků jsou Internetové: CRLF
 - řádky mají maximální velikost 998 znaků (+2 CR a LF)
- zpráva se skládá z hlavičky a těla zprávy
 - tyto dvě části jsou odděleny prázdným řádkem
- položky hlavičky se skládají z jména položky, které následuje dvojtečka (bez mezery, např. Subject:) a za ním následuje obsah položky
 - obsah některých položek má pevný formát (adresy, datum, ...), tzv. strukturované položky
 - jiné položky mají volný formát, tzv. nestrukturované položky
 - položky mohou být rozděleny na několik řádek, pak pokračující řádky musí začínat bílým znakem (mezera, tabelátor, ...)
 - na pořadí položek *nezáleží*
- tělo obsahuje řádky textu v US-ASCII

Formát zprávy

Received: from SKOPALOVA (mx.vsfs.cz
[213.210.148.2]by smtp.nextra.cz (Postfix)
with ESMTP id 92EBE5DA0 for <qiq@ucw.cz>; Tue,
12 Apr 2005 09:53:46 +0200 (CEST)

From: Hana Skopalova <hana.skopalova@vsfs.cz>

To: Miroslav Spousta <qiq@ucw.cz>

Subject: Vyuka

Date: Tue, 12 Apr 2005 09:58:40 +0200

Dobry den, nezapomente na vyuku!

Položky SMTP hlavičky

- **From:**
 - adresa odesilatele (člověk, proces, ...), povinná položka
- **Sender:**
 - skutečný odesílatel zprávy (např. sekretářka)
- **Reply-To:**
 - adresa, na které se očekává odpověď, používá se např. u konferencí
- **To:, Cc:, Bcc:**
 - příjemce zprávy, příjemce kopie, příjemce slepé kopie (ostatní nevidí)
 - povinná je aspoň jedna z těchto tří položek
- **Date: nebo Resent-Date:**
 - čas odeslání (přeposlání) zprávy, formát:
 - **Tue, 19 Apr 2005 18:37:52 +0200**
 - povinná položka

Položky SMTP hlavičky

● **Received:**

- cesta, kudy e-mail putoval internetem
- každý MTA po cestě přidá na začátek zprávy tuto položku
- nesmí měnit obsah předcházejících položek
- posloupnost umožňuje vystopovat, kudy zpráva prošla (a jak)
 - první věc, na kterou se zaměřit při diagnostice problémů
- má mnoho volitelných položek: from (odkud), by (kým), via (fyzická cesta), with (protokol), id (identifikace u příjemce), for (obálková adresa)
- jedna povinná položka: čas a datum

● **Return-Path:**

- kam se posílá zpráva zpět jako nedoručitelná

● **Subject:**

- stručný obsah zprávy

Položky SMTP hlavičky

- **Message-Id:**

- identifikace zprávy
- měla by být unikátní v Internetu, přesný formát není definovaný
- dá se podle ní identifikovat, zda se jedná o tutéž zprávu, nebo ne
- hodí se např. pro detekci smyček

- **X-:**

- speciální (rozšiřující) hlavičky, jsou ignorovány
- např.: X-Status, X-Mailer, X-Spam-Status, ...

- **Status:** a další nestandardní hlavičky

- přidává např. MUA pro zapamatování, jestli zpráva byla přečtena, nebo ne

Formát adresy

- dřívější formát: *login@host.domena*
 - např. *qiq@jabberewock.ucw.cz*
 - adresa je vázána na počítač
 - málo pružné (co když přibude nový server?)
- dnes se používá: *jmeno@domena*
 - např. *qiq@ucw.cz*
 - z DNS se zjistí, na který stroj se doručuje pošta pro doménu ucw.cz
 - může jich být víc
- formát zápisu adresy dle RFC 822:

jmeno@domena

Identifikace <jmeno@domena>

jmeno@domena (Identifikace)

Poznámky k adresám

- doménová část adresy není case-sensitive (DNS)
- to, co je před znakem „@“ může a nemusí být case-sensitive
 - záleží na implementaci – MUA musí počítat s tím, že na velikosti písmen záleží
- URL je ve formátu <mailto:qiq@ucw.cz>
- adresa Postmaster@domena by měla být vždy platná a měl by ji číst správce daného poštovního serveru

Doručení pošty

- zpráva je ze stanice odesilatele předána pomocí protokolu SMTP serveru (MTA) ke zpracování
- MTA zprávu přijme a převezme za ni zodpovědnost
 - většinou ji uloží na disk
 - má za úkol zprávu doručit na cílový mail server, případně ji vrátit zpět jako nedoručitelnou
- MTA zjistí z DNS poštovní servery (může jich být víc) pro danou doménu (MX záznam v DNS pro danou doménu)
 - neexistuje-li v DNS MX záznam pro danou doménu, zkusí najít A záznam a na tuto adresu zprávu doručit
 - MX záznamy mají přiřazenou prioritu – nejnižší číslo znamená nejvyšší prioritu
- MTA se pokusí doručit zprávu na cílový server (servery) podle priority
 - pokud se mu to nevede, zpráva zůstává ve frontě na daném MTA

Doručení pošty (2)

- cílový MTA zprávu předá MDA k uložení do uživatelské schránky
 - odtud si ji uživatel pomocí MUA může vyzvednout
 - případně pomocí protokolů POP3 nebo IMAP
- pokud se MTA nedaří doručení po určitou dobu (typicky 5 hodin), pošle odesilateli (Return-Path:) upozornění, zprávu si nadále ponechá ve frontě
- pokud se MTA nedaří doručení po dlouhou dobu (3 dny), vrátí zprávu jako nedoručitelnou
- obecně se předpokládá, že poštovní servery budou mít permanentní připojení k Internetu
 - pokud některý server není přímo připojen, měl by existovat jiný poštovní server pro danou doménu, který bude mít nižší prioritu
 - doručení zpráv proběhne po připojení „primárního“ mail serveru

SMTP

- Simple Mail Transfer Protocol, RFC 821 (2821)
- definuje, jak vypadá komunikace mezi MTA
 - a mezi MUA a MTA při poslání zprávy
- přenáší RFC 822 zprávy
- vychází z původních požadavků
 - jednoduchost, efektivita: textový protokol
 - snadná rozšiřitelnost: ESTMP
 - přenos US-ASCII znaků: 7bitový přenos
- rozdělení (analogie klasické pošty):
 - list papíru: zpráva (hlavička – jako na hlavičkovém papíru)
 - obálka: součást SMTP protokolu (některé položky se opisují i do zprávy)
- SMTP přenáší zprávy podle obálek, ne podle obsahu (listu papíru)

Obálka a zpráva

From: <qiq@ucw.cz>
To: <test@mail.vsfs.cz>
Subject: test testov testovic

RFC 822

testosteron

RFC 821

MAIL FROM: <qiq@seznam.cz>
RCPT TO: <test@mail.vsfs.cz>

SMTP protokol

- spojení probíhá na portu 25 (587)
 - na IP adresu MX nebo A DNS záznamu pro danou doménu
- nejprve se servery vzájemně pozdraví příkazem HELO
- poté odesílající server předá cílovému serveru údaje z hlavičky
- odesílatel: MAIL FROM: <qiq@ucw.cz>
- příjemce: RCPT TO: <spousta@mail.vsfs.cz>
- následuje příkaz DATA, po kterém se pošle celá zpráva (hlavičky následované prázdným řádkem a tělem zprávy)
- nakonec se spojení ukončí: QUIT
- v rámci jednoho spojení je možné poslat několik zpráv (HELO se zadává pouze napoprvé, pak už jen MAIL FROM, RCPT TO, DATA)

SMTP konverzace

```
S: 220 www.example.com ESMTP Postfix
C: HELO mydomain.com
S: 250 Hello mydomain.com
C: MAIL FROM: <sender@mydomain.com>
S: 250 Ok
C: RCPT TO: <friend@example.com>
S: 250 Ok
C: DATA
S: 354 End data with <CR><LF>.<CR><LF>
C: Subject: test message
C: From: sender@mydomain.com
```

```
C: To: friend@example.com
C:
C: Hello,
C: This is a test.
C: Goodbye.
C: .
S: 250 Ok: queued as 12345
C: quit
S: 221 Bye
```

SMTP: chybové kódy

- chyby a stavy v číselné a textové podobě
 - text je určen pro administrátory/uživatele
 - číslo udává, co nastalo za chybu
- číslo je tříciferné, každá cifra udává jiný typ informace
 - první cifra: úspěch (1-3), chyba (5), dočasná chyba (4)
 - druhá cifra: kategorie chyby: syntax (0), spojení (2), zpráva (5)
 - třetí cifra: konkrétní chyba v dané kategorii

SMTP: chybové kódy

- 211 System status, or system help reply
- 214 Help message
- 220 <domain> Service ready
- 221 <domain> Service closing transmission channel
- 250 Requested mail action okay, completed
- 251 User not local; will forward to <forward-path>
- 252 Cannot VRFY user, but will accept message and attempt delivery
- 354 Start mail input; end with <CRLF>.<CRLF>
- 421 <domain> Service not available, closing transmission channel
- 450 Requested mail action not taken: mailbox unavailable
- 451 Requested action aborted: local error in processing
- 452 Requested action not taken: insufficient system storage

SMTP: chybové kódy (2)

- 500 Syntax error, command unrecognized
- 501 Syntax error in parameters or arguments
- 502 Command not implemented (see section 4.2.4)
- 503 Bad sequence of commands
- 504 Command parameter not implemented
- 550 Requested action not taken: mailbox unavailable
- 551 User not local; please try <forward-path>
- 552 Requested mail action aborted: exceeded storage allocation
- 553 Requested action not taken: mailbox name not allowed
- 554 Transaction failed

SMTP: poznámky

- adresy uvedené na obálce (v SMTP MAIL FROM: a RCPT TO:) se používají na opravdové doručení zprávy – MTA nehledí na údaje, které jsou uvedeny v hlavičkách(!!)
- Bcc: se řeší tak, že na obálce je skutečný příjemce a zpráva je shodná se všemi ostatními příjemci
 - neboli ze zprávy MUA odstraní Bcc: hlavičku a stejnou zprávu pošle na všechny adresy v To:, Cc: a Bcc:
- RCPT TO: se může v SMTP dialogu opakovat (šetříme pásmo – zpráva se přenáší po lince pouze jednou)

SMTP: další příkazy

- VRFY
 - ověří, že adresát existuje
 - dnes se kvůli spammerům/hackerům zakazuje
- EXPN
 - zobrazí obsah distribučního listu (seznam adres)
 - platí o něm to samé, co o VRFY
- RSET
 - zrušení přenosu zprávy
- NOOP
 - prázdná operace
- HELP
- QUIT

ESMTP

- extended SMTP (RFC 1651)
 - rozšíření SMTP o další možnosti
 - místo HELO na počátku konverzace se použije příkaz EHLO
 - pokud projde, MTA podporuje ESMTP, vypíše podporovaná rozšíření
- doručení (pozitivní i negativní): DSN
 - delivery status notification
 - RFC 1891
- maximální velikost mailu: SIZE
 - umožňuje serveru odmítnout příliš velkou zprávu ještě před začátkem přenosu
- pipeline režim: PIPELINING
 - umožňuje vykonávat více příkazů bez čekání na odpověď server
- osmibitový přenos (není potřeba speciální kódování pro MIME): 8BITMIME

MIME

- Multipurpose Internet Mail Extensions, RFC 2045 – 2049
 - používá se nejen pro poštu, ale je součástí i např. HTTP
- mechanismus, jak přenášet pomocí SMTP libovolné zprávy
 - strukturované, binární, ...
- zpětně kompatibilní
 - dnes všechny MUA podporují MIME
- SMTP přenáší data sedmibitově
 - nejvyšší bit nemusí být přenesen
 - a omezuje maximální délku řádku na 998
- MIME přidává k datům jejich popis (typ)
- používá speciální kódování (BASE64 a quoted printable), aby přeneslo binární (osmibitová) data přes 7bitový kanál
- definuje také kódování dat v položkách hlavičky

MIME typ

- RFC 2046
- MIME typ se skládá ze dvou částí: obecného typu a (konkrétního) podtypu
 - odděleny jsou lomítkem
 - registruje IANA
- obecný typ: text, application, image, audio, video, message, multipart, model
- text/plain, text/html, text/rtf...
 - čistě textové části
 - může u nich být uvedeno kódování (text/html; charset=iso-8859-2)
- application/postscript, application/msword, application/octet-stream
 - binární data, spustitelné soubory
- image/jpeg, image/png, image/gif, image/tiff, ...
 - obrázky

MIME typ (2)

- audio/mpeg, ...
 - audio soubory
- video/mpeg, video/quicktime, ...
 - video soubory
- message/rfc822
 - vložená zpráva (podle RFC (2)822)
 - tedy hlavičky a tělo zprávy
 - např. chybové hlášení, odpověď s vloženým původním dopisem, ...
- message/partial
 - část zprávy
 - používá se v případě, že chceme odeslat velkou zprávu (kterou servery po cestě nepodporují)
 - klient sestaví části do původní zprávy

MIME typ multipart

- multipart/mixed
 - různé typy příloh (částí)
- multipart/alternative
 - části jsou vzájemně zástupné – MUA ukáže tu, kterou umí zobrazit nejlépe
 - např. text/plain a text/html
- musí obsahovat atribut (parameter boundary)
 - udává, kde začínají jednotlivé části
 - oddělovač je uvozen --, musí být na začátku řádku
 - poslední oddělovač je zakončen také pomocí --
 - každá část se skládá z hlavičky, prázdného řádku a těla (vlastně jako rfc822 zpráva)
 - v této hlavičce jsou pouze MIME položky
 - pokud není uveden typ (Content-type), použije se text/plain; charset=US-ASCII

MIME

```
From: Denis Vlasenko <vda@port.imtp.ilyichevsk.odessa.ua>
To: linux-kernel@vger.kernel.org
MIME-Version: 1.0
Content-Type: Multipart/Mixed; boundary="Boundary-00=_uNKZC5QbjnCd98x"

--Boundary-00=_uNKZC5QbjnCd98x
Content-Type: text/plain; charset="koi8-r"
Content-Transfer-Encoding: 7bit
Content-Disposition: inline
This + next patch were "modprobe tcrypt" tested.

--Boundary-00=_uNKZC5QbjnCd98x
Content-Type: text/x-diff; charset="koi8-r"; name="1.be.patch"
Content-Transfer-Encoding: 7bit
Content-Disposition: attachment; filename="1.be.patch"
...
--Boundary-00=_uNKZC5QbjnCd98x--
```


MIME: položky hlavičky

- informace o MIME se ukládají v hlavičkách zprávy
- zprávy mohou být rozčleněny do několika částí (stromová struktura)
 - pomocí typu multipart
- povinná položka hlavičky: **MIME-Version**
 - v současné době 1.0
- volitelné položky: **Content-type**, **Content-transfer-encoding**, **Content-id**, **Content-description**, **Content-disposition**
- **Content-type**
 - udává, jakého typu je daná zpráva (MIME type)
 - např. prostý text v ASCII: text/plain; charset=US-ASCII
- **Content-transfer-encoding**
 - jaké se použilo kódování pro přenos: např. quoted-printable, base64, 7bit, 8bit 33

BASE64

- způsob kódování 8bitových znaků pomocí šesti bitů (3x8b -> 4x6b)
- vstupní znaky (bitová reprezentace) se rozdělí na šestice bitů, a ta se zakóduje pomocí malých a velkých písmen, čísel a znaků „/“ a „+“
- vzájemně jednoznačné přiřazení (je potřeba dekodovat :-))
- hodí se pro binární data, formátuje se na řádky dlouhé 72 znaků

P ř í š e r k á m

01010000	11111000	11101101	10111001	01100101	01110010	01101101	11100001	01101101			
010100	001111	100011	101101	101110	010110	010101	110010	011011	011110	000101	101101

U P j t u W V y a + F t

0	1	2	3	...	25	26	27	28	...	51	52	53	...	61	62	63
A	B	C	D	...	Z	a	b	c	...	z	0	1	...	9	+	/

Quoted printable

- znaky, které jsou součástí US-ASCII necháme tak, jak byly
- ostatní znaky zakódujeme sekvencí „=“ následované hexadecimálním vyjádření znaku
 - např. v iso-8859-2 má „ř“ hexadecimální kód 0xF8, v quoted printable tedy „ř“ bude =F8
 - platí i pro „=“, ...
- výhodné pro texty, ve kterých je poměrně málo znaků mimo US-ASCII
- texty zakódované pomocí quoted printable mají řádky dlouhé maximálně 76 znaků (pokud jsou delší, rozdělí se)
Příšerkám => P=F8=ED=B9erk=E1m

MIME: další položky hlavičky

- **Content-id**

- identifikace části zprávy
- např. pro multipart/alternative zprávy vyjadřuje, které zprávy jsou přímo zastupitelné (stejně id)

- **Content-description**

- popisuje obsah, nezpracovává se, pouze se zobrazí uživateli

- **Content-disposition**

- **inline** –zobrazit jako součást zprávy
- **attachment** –zobrazit zvlášť jako přílohu, může mít atribut filename se jménem souboru, který je přiložen (při uložení přílohy se vytvoří soubor s tímto jménem)


MIME: hlavičky

- kromě těla zprávy je potřeba přenášet národní znaky i v položkách hlavičky
 - Subject, From, To, ...
- MIME umožňuje v položce hlavičky uvést řetězec speciální řetězec ve formátu: =?xxx?yyy?zzz?=
 - xxx je použitá znaková sada (např. iso-8859-2)
 - yyy je použité kódování (znak B pro BASE64, Q pro upravené quoted printable)
 - u Q může být mezera nahrazena znakem „_“, nebo =20, bílé znaky jsou kódovány, ...
 - zzz je zakódovaná zpráva
- příklady:
 - From: =?iso-8859-2?Q?Hana_Skopalov=E1?= <hana.skopalova@vsfs.cz>
 - Subject: =?iso-8859-2?B?UmU6ILlrb2xu6Q==?=

Vyzvednutí pošty

- MDA doručí zprávu do schránky adresáta
 - do souboru, databáze, ...
 - jak se k ní klient (MUA) dostane?
 - MTA by měl být trvale připojen k Internetu, MUA být nemusí
- přímý přístup (mbox, maildir, databáze, ...)
 - MUA běží na stejném počítači, nebo je schránka exportovaná přes FS
 - klient musí rozumět formátu schránky
 - je potřeba zamykat schránku (přistupuje současně MUA a MDA)
- vzdálený přístup
 - protokoly POP a IMAP (pouze vyzvednutí, posílání – SMTP(!))
 - umožňují přistupovat ke schránce z libovolného počítače v Internetu
 - standard, RFC
 - liší se ve filosofii a možnostech

Vyzvednutí pošty



POP3

- Post Office Protocol verze 3, RFC 1939
- používá TCP, port 110
- protokol je textový (podobně jako SMTP), velmi jednoduchý
- umožňuje stáhnout zprávy ze schránky na klientský počítač (do MUA)
 - neboli zprávy se doručí na klientský počítač
- hodí se pro *off-line* MUA, který se připojuje k serveru pouze na omezenou dobu (pro přenos zpráv)
- umožňuje přistupovat pouze do jedné schránky (INBOX)
- některé servery umožní ponechání zpráv na serveru
 - protokol s tím původně nepočítal
 - případně může být nastaveno mazání přečtených zpráv po uplynutí nějaké doby

POP3 protokol

- příkazy jsou maximálně čtyřpísmenné, argumenty jsou odděleny mezerou
- server vrací odpověď „+OK“, nebo „-ERR“ (následovat může chybová hláška)
- spojení má tři fáze: autentizační (přihlášení uživatele) a transakční (stahování, mazání pošty), aktualizací (opravdové smazání pošty)
- příkazy:
 - USER string (login), PASS string (heslo)
 - LIST (výpis čísel zpráv), RETR n (stažení zprávy) DELE n (smazání zprávy)
 - QUIT (ukončení), RSET („obnovení“ smazaných zpráv)
- existují rozšíření (podobně jako v SMTP)
 - zjišťují se příkazem CAPA
 - např. maximální doba, po kterou může být přečtená zpráva na serveru (EXPIRE)
 - stažení jen části zprávy (např. pouze hlavičky): TOP, unikátní čísla zpráv: UIDL

POP3 protokol

```
S: +OK mail Cyrus POP3 v2.1.18 server
  ready <2330620496.1114241905@mail>
C: USER test
S: +OK Name is a valid mailbox
C: PASS testpass
S: +OK Maildrop locked and ready
C: LIST
S: 1 7609
S: 2 7684
S: 3 7440
S: 4 6965
S: .
C: RETR 1
S: From: xxx@yyy.cz
S: Subject:...
```

```
S:
S: Dobry den!
S: Tesilo me
S: .
C: DELE 1
S: +OK message deleted
C: QUIT
S: +OK
```

IMAP

- Internet Message Access Protocol (verze 4rev1), RFC 3501
- používá TCP, port 143
- původně pouze pro on-line přístup (nižší verze protokolu)
- nyní umožňuje i off-line práci díky cachování zpráv na klientovi
 - dokonce je možné zprávy mazat s tím, že synchronizace se provede později
- zprávy jsou uloženy na serveru
 - na klientovi je pouze kopie zpráv pro rychlejší načítání (cache)
 - jsou stále přístupné, z různých míst v Internetu (např. z práce a z domova (i současně!))
- umožňuje vytvářet hierarchii složek
 - stromová struktura, jména v UTF-7
- umožňuje nastavovat atributy zprávám, přesouvat zprávy mezi složkami
- mnoho různých způsobů autentizace

IMAP protokol

- spojení má čtyři stavy (fáze): neautentizovaný, autentizovaný, vybraný mailbox, logout
- každý příkaz klienta je uvozen identifikací (tag) operace
 - aby bylo možné identifikovat odpověď – je možné paralelně provádět několik operací
- umožňuje přihlašovat a odhlašovat složky
 - většinou se na příchozí poštu kontrolují pouze přihlášené složky
- každá zpráva by měla mít unikátní číslo
- čísla v mailboxech jsou rostoucí (definují pořadí)
- protokol umožňuje vyhledávání na serveru

IMAP protokol

```
S: * OK IMAP4rev1 Service Ready
C: a001 login mrc secret
S: a001 OK LOGIN completed
C: a002 select inbox
S: * 18 EXISTS
S: * FLAGS (\Flagged \Deleted \Seen)
S: * 2 RECENT
S: * OK [UNSEEN 17] Message 17 is the
first unseen message
S: * OK [UIDVALIDITY 385752] UIDs valid
S: a002 OK [READ-WRITE] SELECT completed
C: a003 fetch 12 body[header]
S: * 12 FETCH (BODY[HEADER] {342}
S: Date: Wed, 17 Jul 1996 02:23:25 -0700
S: From: Gray <gray@cac.washington.edu>
```

```
S: Subject: IMAP4rev1 WG mtg summary
S: To: imap@cac.washington.edu
S: cc: minutes@CNRI.Reston.VA.US
S: Message-Id: <B27397-
0100000@cac.washington.edu>
S: MIME-Version: 1.0
S: Content-Type: TEXT/PLAIN; CHARSET=US-
ASCII
S:
S: )
S: a003 OK FETCH completed
C: a004 logout
S: * BYE IMAP4rev1 server terminating
connection
S: a004 OK LOGOUT completed
```

spam

- nevyžádaná sdělení
 - šířená telegramem, telefonem, e-mailem, ...
 - původně z Monty Python
 - později „shit posing as spam“
- komerční: Usenet, 1994
- analogie podomního prodeje
 - dneska letáky ve schránce (junk mail)
- s rozvojem elektronických komunikací nastal jeho masivní rozvoj
 - snadné, levné, masové, účinné
 - je těžké se bránit
- mnoho podob: e-mail, IM, blog, diskuse, spamdexing



e-mail SPAM

- nejrozšířenější forma spamu
- rozesílán na mnoho adres
 - získaných z různých služeb vyžadujících registraci
 - diskusních skupin
 - webových stránek
- rozšířily se antispamové filtry
 - roztočila se spirála zdokonalování spamů a antispamů
 - udává se, že kolem 80% dnešních e-mailů jsou spamy
- zatěžují mailové servery
- znesnadňují komunikaci
 - především antispamy
- spamerů není mnoho, ale dokáží znepríjemnit život stamiliónům uživatelů

Jak poznat spam?

- na počátku obyčejné e-mailů s reklamní tematikou
 - filtrování podle hlaviček/údajů na obálce
 - položky v hlavičce lze snadno měnit (stejně jako u klasické pošty (snail mail))
 - dnes je adresa odesilatele buď neplatná, nebo kradená (a e-mail obsahuje odkaz na web),
 - neboli podle hlavičky e-mailu toho moc nezjistíme
- rozpoznání spamu podle obsahu
 - nejčastěji se jedná o reklamu na Viagru, zvětšení přirození, ...
 - je možné používat stop slova (pokud se v e-mailu najde slovo Viagra, zahodíme ho)
 - není to vhodné (může se objevit i v korektním e-mailu)
 - reakce spamérů: Vlágra

Jak poznat spam? (2)

- podstata spamování: informace je rozesílána na obrovské množství adres
 - nápad: pokud jeden uživatel označí zprávu jako spam, ostatní už to budou vědět
 - měli by vždy označovat lidé
 - kolaborativní síť (razor, pyzor)
 - pozor na zneužití
 - porovnávají se pouze hashe zpráv
 - reakce spamérů: přidávají do zpráv náhodnou část, pro každý spam jinou
 - obrana (částečná): hash počítáme z náhodných částí spamu
- učící se statistický filtr
 - idea: pro každý e-mail spočítáme pravděpodobnost, že se jedná o spam
 - filtr se musí nejprve „naučit“ informace z předhozených spamů a nespamů (hamů)

Bayesovský filtr

- idea: pro každý e-mail spočítáme pravděpodobnost, že se jedná o spam
- pro každé slovo si pamatuje, jaká je pravděpodobnost, že e-mail obsahující dané slovo je spam
 - na počátku vezmeme dvě složky s poštou, jednu se spamem a druhou s hamem
 - pro každé slovo spočítáme $P(w) = \text{počet výskytů } w \text{ (spam)}/\text{počet všech výskytů } w$
 - tím získáme pravděpodobnost, že dané slovo je součástí spamu
 - zde je potřeba učení
- při hodnocení e-mailu se spočítá geometrický průměr z pravděpodobností, že slova v e-mailu určují spam
 - tento postup se kvůli optimalizacím aplikuje pouze na zajímavá slova (ta, která jsou extrémní – buď indikují, že se jedná o spam, nebo ta, která indikují ham)
- filtr je potřeba naučit pomocí hamů pro každého uživatele (skupinu uživatelů zvlášť)

Triky spamerů

- jak zmást bayesovský filtr
 - vkládat nesmyslná slova (budou vytvářet dojem, že se jedná o ham)
 - dneska se používá naopak pro detekci
 - vkládat odstavce z knih, obsahem sdělení je třeba jen obrázek, zbytek se nezobrazí
 - filtrování podle obsahu nefunguje, je potřeba, aby nastoupilo jiné
- filtrování podle hlaviček Received:
 - ty jsou (od jistého bodu) korektní i u spamu
 - existují databáze serverů, ze kterých pochází spam
 - jsou řešené přes DNS (do DNS se položí dotaz, pokud server vrátí odpověď (server zná), jedná se o server posílající spamy
 - spameři začali používat cizí počítače pro rozesílání
 - často jsou to počítače unesené (napadené), nebo tzv. open relay
- open relay: server, který umožňuje každému přeposlat e-mail

Další triky spamerů

- jak zabránit falšování adres v e-mailu?
 - původní RFC s tím nepočítala
 - iniciativa SPF – sender policy framework (<http://spf.pobox.com>)
 - řeší posílání e-mailu s falešnou adresou odesilatele
 - do DNS pro doménu přidává záznam, které servery jsou platné pro odchozí poštu pro danou doménu
 - je snadné zkontrolovat, zda pošta přichází ze serveru, který je platný odchozí server
 - zatím se příliš nerozšířilo (ale např. AOL, gmail, seznam.cz to používají)
- poslat korektně se tvářící e-mail, který obsahuje pouze odkaz na web, kde je reklama
 - dnes existují i databáze takovýchto serverů (spamer si jich nemůže registrovat příliš mnoho – stojí to peníze)
- poslat reklamu jako obrázek – těžko se bude analyzovat
- jako ochrana je také používáno striktní vyžadování RFC

Ochrana proti spamům

- většinou pomocí vyhodnocení obsahu a dalších faktorů
- používá se kombinace několika metod
- každému e-mailu se přiřadí skóre, které určuje, jak moc je to spam
- uživatel si zvolí, kde je hranice
- jedná se o neutuchající boj, podobně, jako v případě virů/červů
- ochrana může být nasazena na MTA (MDA) a/nebo na MUA
 - často společně s kontrolou virů a červů