genua

Statemaschine

für universellere Nutzung von Modulen

Steffen Ullrich, genua
http://noxxi.de/talks.html

```
my $request = Mail::SPF::Request->new(
    identity   => 'foo@example.com',
    ip_address => '192.168.0.1',
    ...
);

my $result = Mail::SPF::Server->new
    ->process($request);
```

DNS Abfragen: **Warten** bis fertig

- Blockiert für DNS-Anfragen
- Parallelisierung nur durch Threads
  Integration in Event-Loops nicht möglich
- genugate Relays sind aber alle event-driven

weitere Mail::SPF Probleme

genua

- Enge Verzahnung von Protokolllogik und I/O Nachnutzung der Protokolllogik unmöglich
- Eigene DNS-Logik (Quellen, Caching...) mit Net::DNS::Resolver kompatiblem Objekt
- DNS Anfragen nur sequentiell, selbst wenn eigener Resolver

genua

```
my $spf = Mail::SPF::Iterator->new(
    $ip, $mailfrom, $helo, $myname);

my ($result,@q) = $spf->next;
while (!$result and my $q = shift(@q)) {
    ... resolve DNS query $q ...
    ($result,@q) =
        $spf->next($dns_answer);
}
```

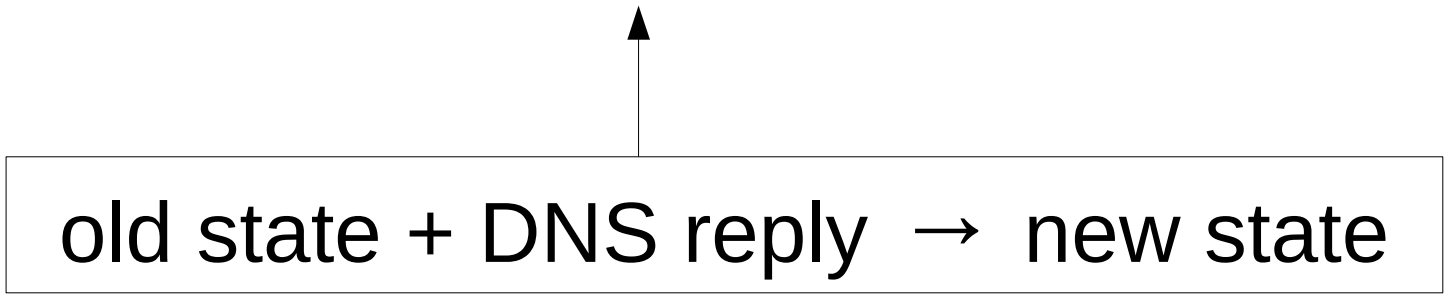

- Push vs. Pull
  - Output: DNS-Anfragen | Endresultat
  - Input: Antworten auf DNS-Anfragen
- Integration in beliebige Event-Loops
  Blockierend arbeiten weiterhin möglich

genua

- Volle Kontrolle über DNS-Lookups
  Timeout, Caching, Quellen, Anzahl, Gesamtzeit ...
  Macht auch Testen einfacher
- Parallele DNS-Lookups möglich
  `next` liefert alle weiteren Anfragen (SPF, TXT, ...)
  Höhere Geschwindigkeit durch Parallelisierung

genua

- Mail::DKIM::Iterator
  - Input:
    DNS-Antworten + Mailchunks
  - Output:
    DNS-Anfragen + „mehr Daten“
    bzw. Endresultat
- Mail::DMARC::Iterator
  kombiniert SPF + DKIM

genua

- Diverse blockierende Bibliotheken
  LWP::UserAgent, HTTP::Tiny, Furl...
- Diverse asynchrone mit eigenem Eventloop
  AnyEvent::HTTP, Mojo::UserAgent
- Verarbeiten von Datenströmen (PCAP...)
  Net::Inspect::L7::HTTP

genua

- Begrenzte Kontrolle des Verhaltens
  über Parameter, Callbacks ...
- Unterschiedliche Features
  Datenkompression ...
- Unterschiedliche Korrektheit
  Chunked Encoding, Keep-Alive ...

- NEEDMORE
  brauche mehr Daten
- HEADER
  Request/Response-Header eingelesen
- BODY
  Payload Daten, evtl. decodiert
- DONE
  Ende des Body
- ERROR
  fataler Protokollfehler
- WARN
  nicht-fatales Problem, z.B. kaputte Headerzeile

genua

```
print $to_server $http_request;
my $state = my::HTTParser->new('response');
my @result = $state->next;
while (@result) {
    my $what = shift(@result);
    if ($what == HTP_NEEDMORE) {
        sysread($cl, my $data, 8192);
        @result = $state->next($data);
    } elsif ($what == HTP_HEADER) {
        my $hdr = shift(@result);
    } elsif ($what == HTP_BODY) {
        my $decoded_payload = shift(@result);
    } elsif ($what == HTP_DONE) {
        last;
    }
    ... HTP_ERROR, HTP_WARN
}
```

- Push statt Pull
  - Input:
    Chunks von Daten
  - Output:
    Done | Need more
    Typisierte Datenchunks
    Informationen zu Problemen

genua

- Unabhängig von Event-Loop
  Auch blockierend verwendbar
- Trennung Protokolllogik und I/O
- Auch ohne Sockets verwendbar, z.B. zur Analyse von mitgeschnittenen Daten
- Volle Kontrolle über applikationsspezifische Abbruchbedingungen, wie Timeouts, Bandbreitenlimits, Größe Response ...

```
while (@result) {
    ...
    } elsif ($what == HTP_HEADER) {
        my $hdr = shift(@result);
        # use raw content not decoded
        $state->decoder(undef);
    } elsif ($what == HTP_BODY) {
        my $raw_payload = shift(@result);
```

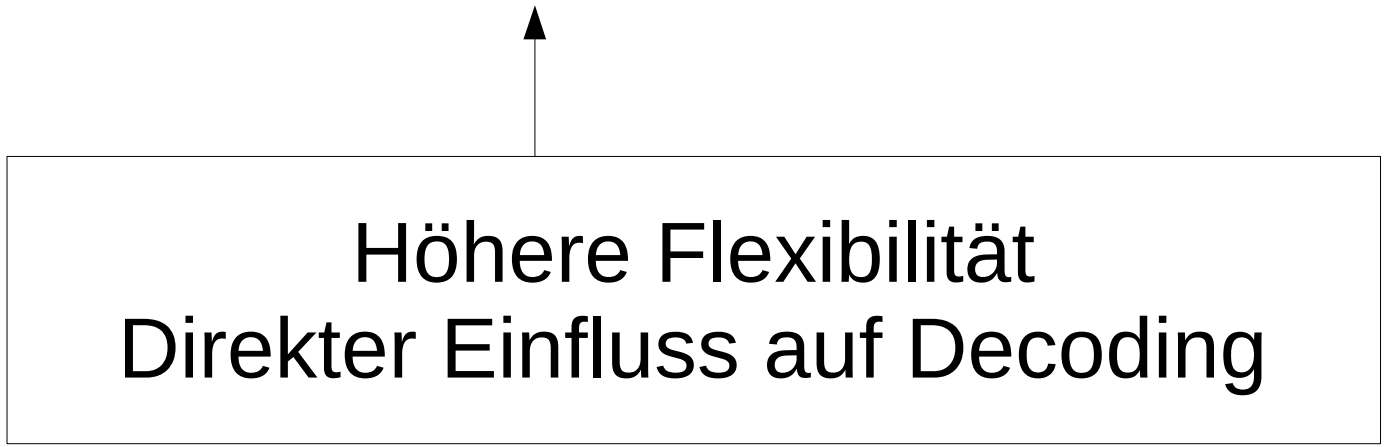

```
my $payload = '';
while (@result) {
    ...
    } elsif ($what == HTP_HEADER) {
        my $hdr = shift(@result);
    } elsif ($what == HTP_BODY) {
        $payload .= shift(@result);
        last if length($payload)>$MAX;
```

Größenkontrolle ohne spezielle Callbacks oder Parameter

- Kann transferiert werden (IMAP, SMTP) oder lokal in unterschiedlichen Formaten vorliegen (Mbox, Maildir, Outlook PSF...)
- Besteht meist aus vielen unterschiedlichen Teilen: Plain-Text, HTML-Text mit Bildern, Attachments, PGP-Signatur ...
- Teile sind kodiert mit quoted-printable, base64, ...

MIME – typische Mail als Text

genua

```
From: foo@example.com
To: bar@example.com
Subject: foobar
Content-type: multipart/mixed;boundary=foo

--foo
Content-type: multipart/alternative; boundary=bar

--bar
Content-type: text/plain; charset=iso-8859-15
Content-Transfer-Encoding: quoted-printable

text =C4rger ...
--bar
Content-type: text/html
Content-Transfer-Encoding: base64

CjwhZG9jdHlwZSBodG1sPiA...
--bar--
...
```

MIME – typische Mail als Struktur

genua

- Mail mit Text und PDF-Attachments
- Text als Plain und HTML
- HTML mit eingebettem Firmenlogo

```
multipart/mixed
|- multipart/alternative
|   |- text/plain (quoted-printable)
|   |- multipart/mixed
|   |   |- text/html (base64)
|   |   |- image/png (base64)
|- application/pdf (base64)
```

- Vielfalt unterschiedlicher Aufgaben
  - Attachments auf Malware überprüfen (extrahieren, decodieren)
  - Attachment für Transport in IMAP bereitstellen (extrahieren, nicht decodieren)
  - Filenamen Attachment ermitteln um z.B. *.exe zu blockieren (nur Analyse Header)
  - Text-Teil optimal anzeigen, z.B. nur Plain oder HTML mit Bildern
  - ...

genua

- Existieren diverse Parser für Mail
  Mail::Parser, Email::MIME
- Wollen alle volle Kontrolle über Filehandle
  Extraktion aus Mailbox oder anderen Quellen nur über Umwege
- Blockierendes Lesen
  Parallelisierung nur über Threads
  Keine eventbasierte Verarbeitung

genua

- Begrenzte Einflussnahme, ob und wie extrahierte Daten abgelegt werden
- Analyse der MIME-Parts erst nach kompletter Verarbeitung möglich, kein Streaming
- Alles wird extrahiert und decodiert, nicht nur die benötigten Teile

genua

- Trennung Protokolllogik und I/O
  Streaming Parser mit Push der Daten
  Datenquelle egal: Datenbank, MBox, Socket...
- Spamanalyse und Virenscanning ermöglichen noch bevor die Mail komplett gelesen ist
- Optimierungen, Parametrisierung on-the-fly
  - Decoding nach Bedarf
  - Überspringen von MIME-Parts

genua

- NEEDMORE
  brauche mehr Daten
- SINGLEPART_HEADER, MULTIPART_HEADER
  Header des Parts eingelesen
- BODY
  Payload Daten, evtl. decodiert
- MULTIPART_DONE, DONE
  Ende einer Multipart-Section bzw. der Mail
- ERROR, WARN

Nutzung im Code (PoC)

genua

```
my $parser = my::MIME::Parser->new;
my @result = $parser->next;
while (@result) {
   my ($what,$arg) = splice(@result,0,2);
   if ($what == MIME_NEEDMORE) {
      sysread($fh,my $buf,8192);
      @result = $parser->next($buf);
   } elsif ($what == MIME_SINGLEPART_HEADER) {
      ...
   } elsif ($what == MIME_MULTIPART_HEADER) {
      ...
   } elsif ($what == MIME_BODY) {
      ...
   } elsif ($what == MIME_DONE) {
      ...
```

genua

- Push statt Pull
  - Input:
    Chunks von Daten
  - Output:
    Done | Need more
    Typisierte Datenchunks
    Informationen zu Problemen

MIME Statemaschine in Aktion

```
multipart/mixed
            [0] MULTIPART_HEADER
 - multipart/alternative
            [1] MULTIPART_HEADER
    - text/plain (quoted-printable)
            [2] SINGLEPART_HEADER
            [2] BODY*
    - text/html (base64)
            [2] SINGLEPART_HEADER
            [2] BODY*
            [1] MULTIPART_DONE
 - application/pdf (base64)
            [1] SINGLEPART_HEADER
            [1] BODY*
            [0] MULTIPART_DONE
            [*] DONE
```

genua

- Unabhängig von Event-Loop
  Auch blockierend verwendbar
- Trennung Protokolllogik und I/O
- Unabhängig von Datenquelle
  EML-Datei
  einzelne Mails aus MBox
  Netzwerkdatenstrom
  PCAP-Daten
  ...

Nur interessante Attachments

genua

```
..
} elsif ($what == MIME_SINGLEPART_HEADER) {
   if ($arg->get('content-disposition')
      !~m{^attachment\b}i) {
      $parser->skip_part;
   } else {
      .. open $attach_fh ...
   }
} elsif ($what == MIME_BODY) {
   print $attach_fh $arg;
```

Wunsch:
Statemaschine MIME-Generator

genua

- Streaming Generator mit Push der Daten
- Konstruktion neuer Mails ohne Zwischenspeichern oder großen Speicherverbrauch
- Zusammen mit streaming Parser selektive Veränderung von Mail, z.B. Ersetzen von Attachments

genua

- HTML
  HTML::Parser ist callback-driven
- XML – alles callback driven
  XML::LibXML::Iterator
  XML::Parser
  XML::SAX::*
- Callbacks evtl. blockierend, z.B. zum Auflösen externer Entities

Statemaschine – so nicht

genua

- OpenSSL ist fast eine Statemaschine
  Push über BIO Funktionen
- Einige wichtige Sachen jedoch über Callbacks realisiert
  - Behandlung von SNI
  - Validierung von Zertifikaten
- Dumm, wenn diese Callbacks blockieren

Anwendungsfall SSL Inspection und SNI

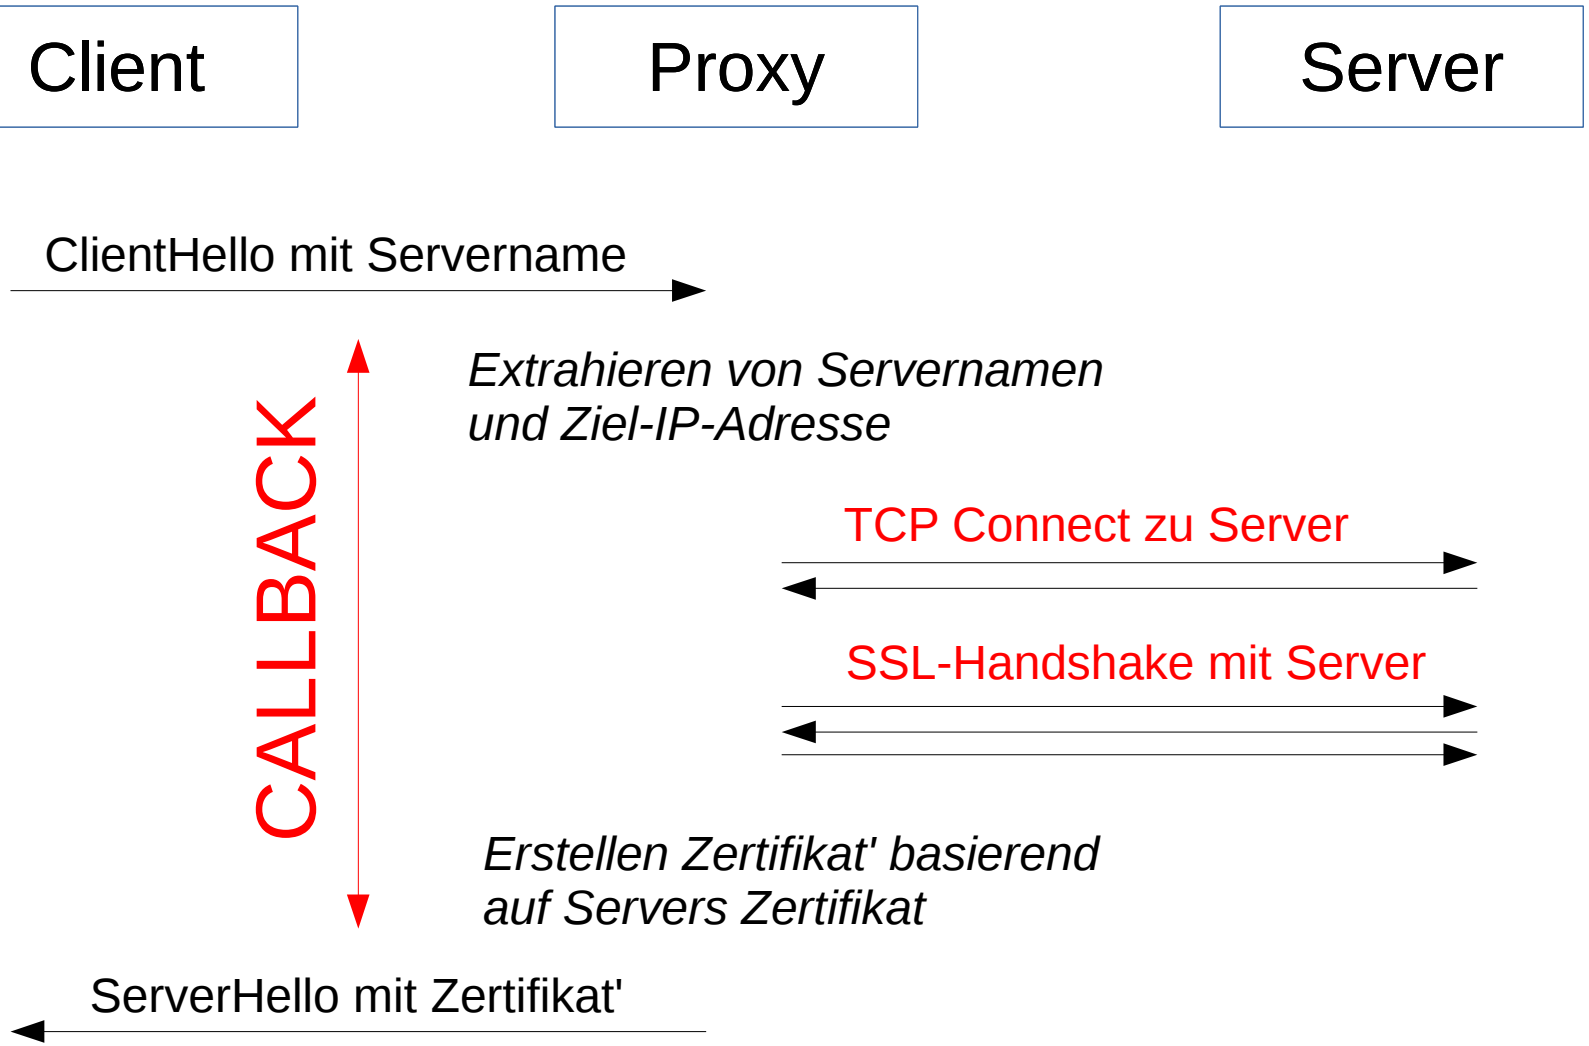

genua

- Statemaschine ist mächtiges Konzept
  - Push vs. Pull:
    Einsatz in blockierenden und eventbasierten Situationen
  - Trennung Protokolllogik und I/O:
    Einsatz außerhalb traditioneller Situationen, z.B. zur Analyse von Datenmitschnitten
  - Höhere Flexibilität ohne spezielle Callbacks und Parametrisierungen
  - einfache Serialisierung des States für Persistenz