

How dynamic are IP Addresses?

Paper

“How dynamic are IP Addresses?”

Y. Xie, F. Yu, K. Achan, E. Gillum, M. Goldszmidt, T. Wobber

Network Architectures: Internet Routing
WS 2007/08

Benjamin Vahl

- **Thematik des Papers?**
 - Erkenntnisse über Charakteristiken dynamischer IP Adressen
 - Anwendung beim automatischen Identifizieren
 - Umsetzung: Algorithmus *UDmap*

- **IP-Blacklisting**
 - SpamMail-Server, Botnet-Clients, Phishing-Sites ect. fast ausschliesslich von Rechnern hinter dynamischen IP-Adressen
 - Bisherige Gegenmaßnahme: Blacklisting-Dienste
 - **Nachteile:**
 - Listen nie aktuell
 - veralten schnell / Einträge werden redundant
 - unvollständig

How dynamic are IP Addresses?

Alternative ← Motivation

- Alternative
 - Automatisiertes Erkennen dynamischer IP-Blöcke durch Algorithmus
 - Blocken zugehöriger IPs

- Theorie: Analyse dynamischer IPs
 - Eigenschaften
 - Rückschlüsse auf IP-(Block)-Nutzung
- Anwendung: *UDmap*
 - Voraussetzungen / Ergebnisse
 - Workflow

Eigenschaften dynamischer IP-Adressen

- Trivial
 - Dynamische IP-Adresse ist nacheinander **mehreren Benutzern zugeordnet**
 - entsprechende Benutzer verwenden längerfristig unterschiedliche IPs

- Auftreten in Blöcken
 - dynamische IP-Adressen fast immer Teil eines zusammenhängenden Bereichs (Pool)
 - Blöcke meistens Teilbereich eines IP-Prefixes
 - IP-Adressen innerhalb eines Blocks weisen ähnliche Charakteristiken auf
⇒ Rückschluss auf Zugehörigkeit

▪ IP-Benutzungsentropie

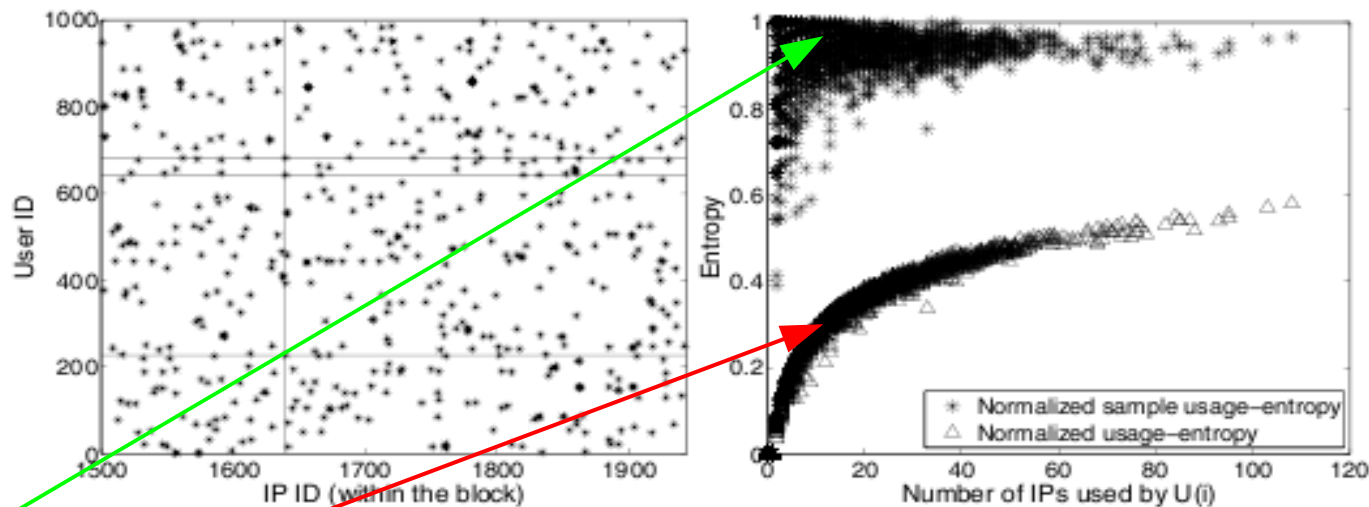
- Benutzer bewegen sich mit ihren IPs innerhalb des Blocks
- Wahrscheinlichkeit für Vergabe der IP innerhalb des Blocks **gleichmäßig verteilt**
- Benutzungsentropie $\hat{=}$ Wahrscheinlichkeitswert

How dynamic are IP Addresses?

Entropie ← Analyse

■ IP-Benutzungsentropie

■ Beispiel



$U(i)$: Gruppe von Benutzern mit IP_i

■ $U(i)$ erhält eine beliebige andere IP aus dem gesamten Block

■ $U(i)$ erhält beliebige IP des Blocks aus der Menge der tatsächlich insgesamt von $U(i)$ verwendeten IPs

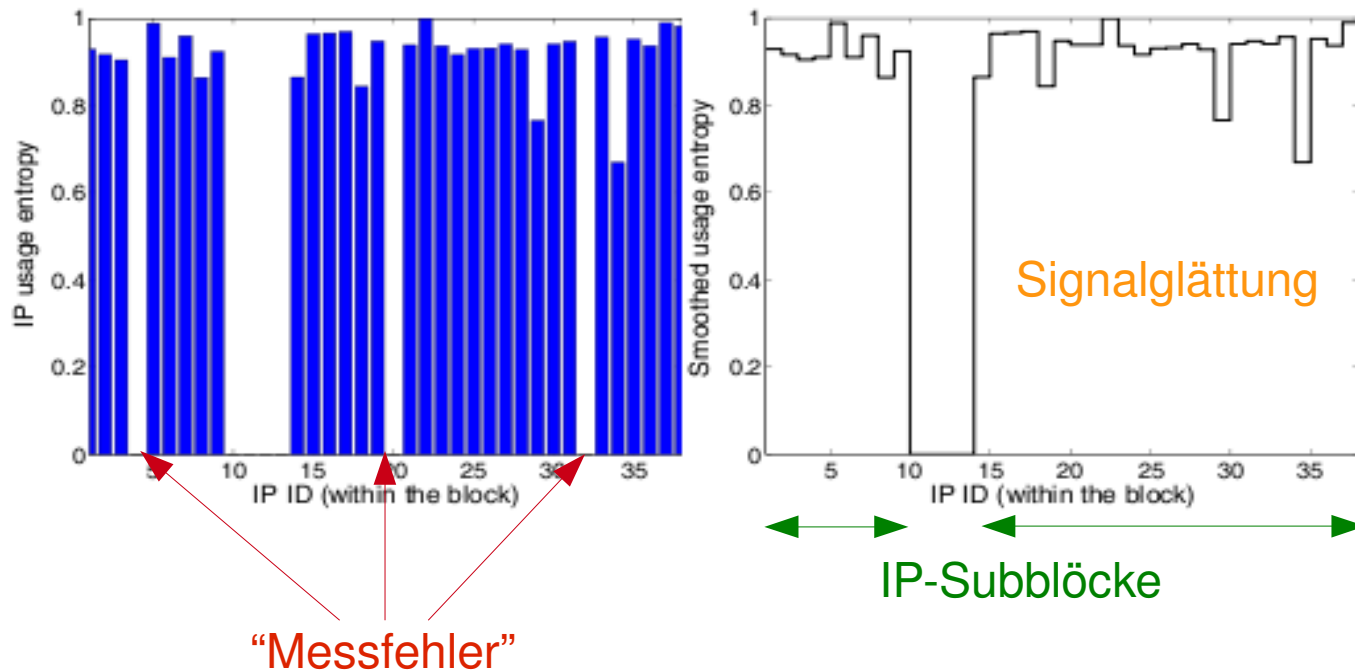
- Anwendung der Entropie
 - Entropiewert $\rightarrow 1$ lässt auf dynamische IP schließen
 - Zusammenfassung zu IP-Block erfordert Entropie der Mehrheit aller enthaltenen Adressen über Schwellenwert
 - Einsetzen von Signalglättung zur Korrektur von Ausreißern

How dynamic are IP Addresses?

Analyse dynamischer IPs

- Anwendung der Entropie
 - Beispiel

Signalglättung



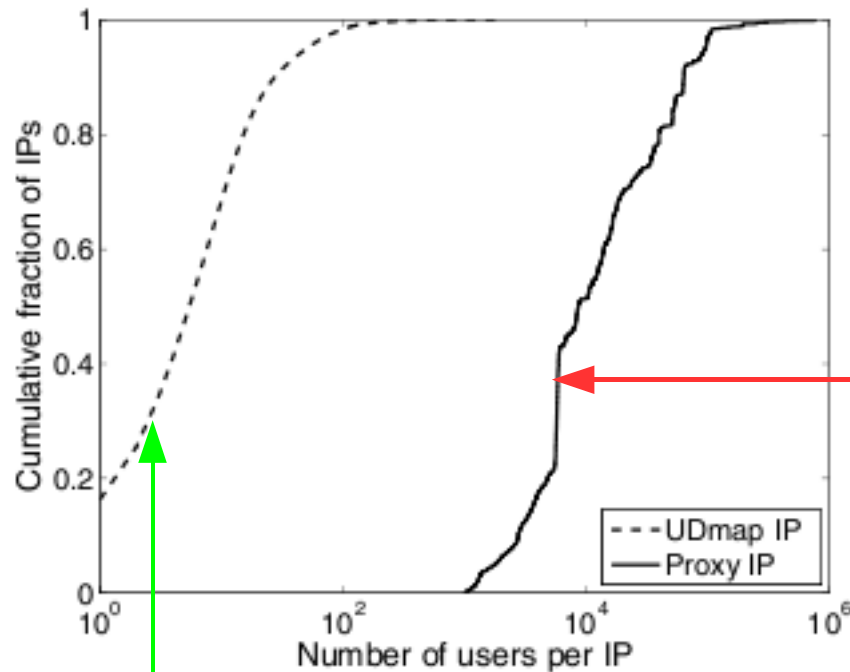
- IP-Volatilität
 - Maßeinheit für **Rate des Benutzerwechsels** einer dynamischen IP
 - Zeitraum gibt Aufschluß über Nutzungsart
 - mittlere Benutzungsdauer und Benutzer pro IP ausschlaggebend

- IP-Volatilität
 - hilft, dynamische IPs von Proxies oder öffentlich genutzten Rechnern zu unterscheiden
 - sehr kurzfristig ⇒ Proxy
 - längerer Zeitraum ⇒ echte dynamische IP

How dynamic are IP Addresses?

IP-Volatilität ← Analyse

▪ Benutzer pro IP-Adresse



(a) Number of users

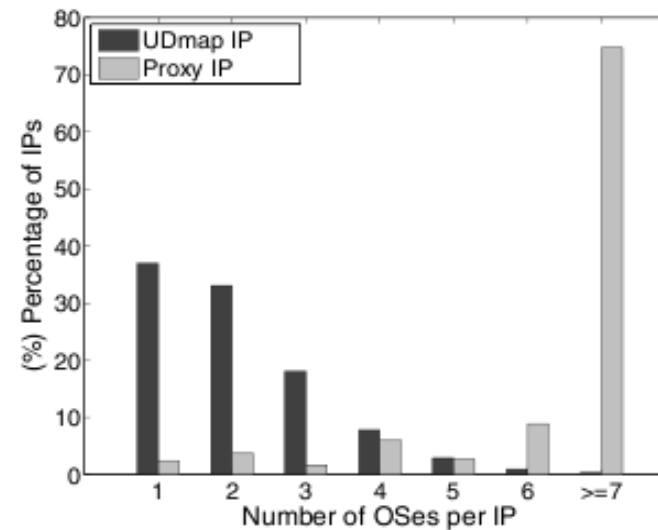
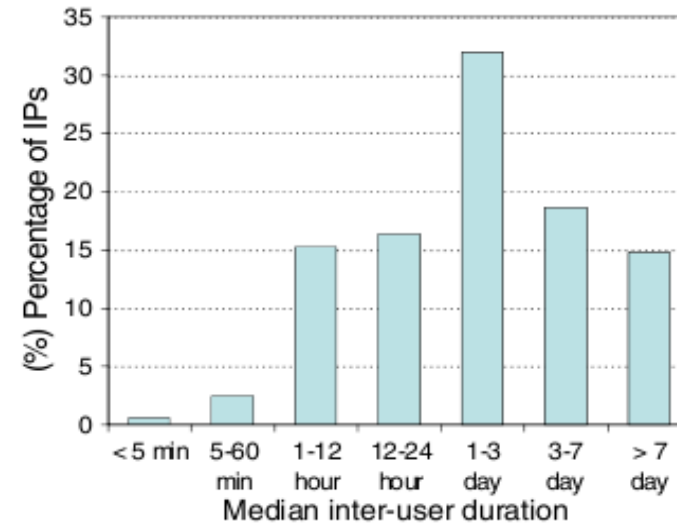
▪ Proxy-Server, ect.
(false positives)

▪ dynamische IP-Adressen

How dynamic are IP Addresses?

IP-Volatilität ← Analyse

- mittlere Benutzungsdauer
- Betriebssysteme pro IP



- **Streuungsfaktor**
 - IPs innerhalb eines Blocks sollten erwartungsgemäß **ähnliche Volatilitätseigenschaften** besitzen
 - Streuungsfaktor quantifiziert Streuung der Volatilität, je größer desto stärker verteilt
 - $\hat{=}$ normalisiertem Abstand zwischen 90% des Maximalwertes und dem Mittelwert

- Erkenntnisse
 - Anzahl der Benutzer pro IP gleichmäßiger verteilt als die mittlere Benutzungsdauer
 - Kleinere Blöcke weisen meistens geringere Streuung auf, als größere

- reverse DNS

- Untersuchen des **rDNS-Records** bietet die einfache Informationsquelle über IP-Adressen zu treffen

- Beispiel:

IP: 157.57.215.19

Hostname: `ads1-dc-305f5.ads1.wanadoo.nl`

⇒ ADSL Anschluss in den Niederlanden

■ Probleme

- Längst nicht alle Domains bieten für ihre IP-Adressen rDNS Records an
- Einige rDNS-Namen sind nicht ausreichend informativ

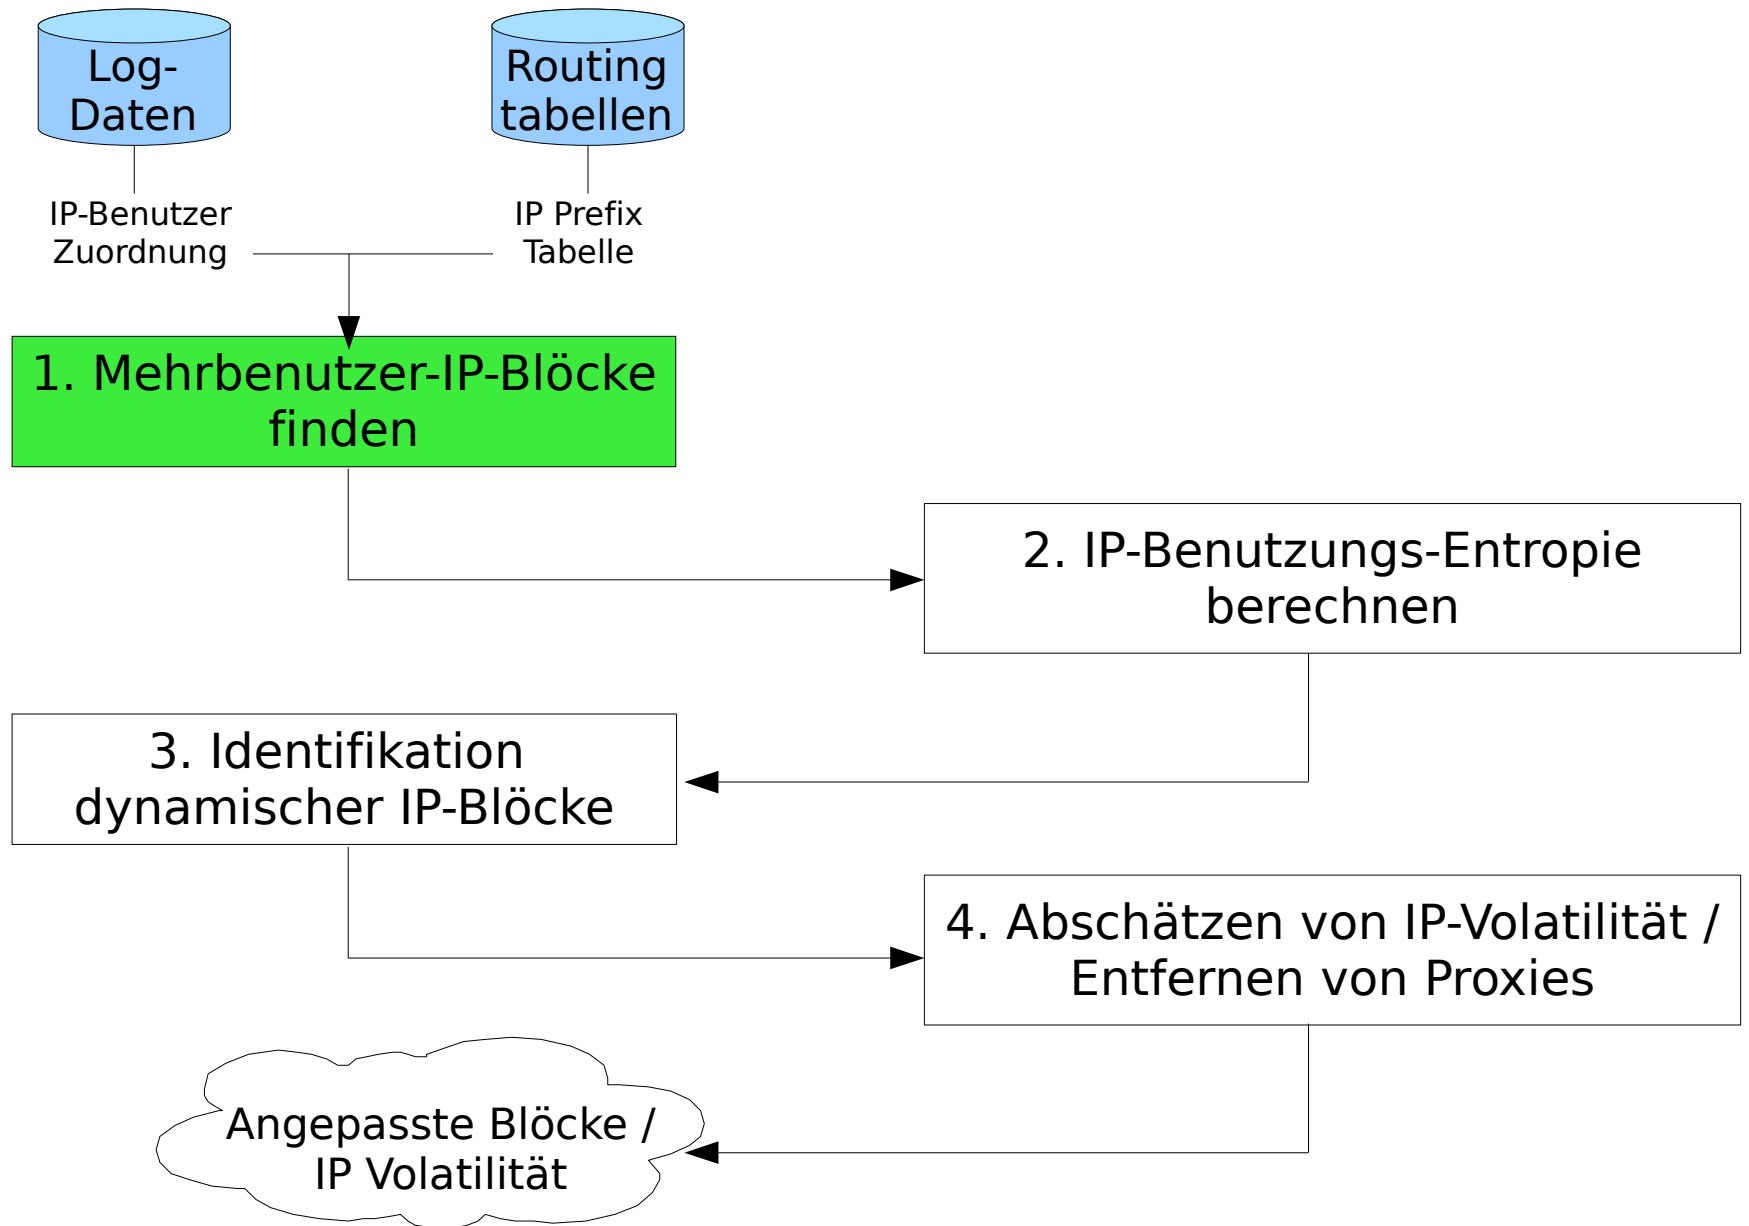
Umsetzung: Algorithmus UDmap

- Voraussetzungen
 - Log-Dateien beliebigen Formats, die Host/Benutzer-IP-Zuordnung und ggf. Betriebssystem ermöglichen
 - Informationen über Netztopologie

- Ergebnisse nach Verarbeitung
 - möglichst präzise eingegrenzte dynamische IP-Blöcke
 - keine IPs von Proxy-Servern oder öffentlich zugänglichen Rechnern
 - IP-Volatilitätswerte

How dynamic are IP Addresses?

Workflow ← UDmap

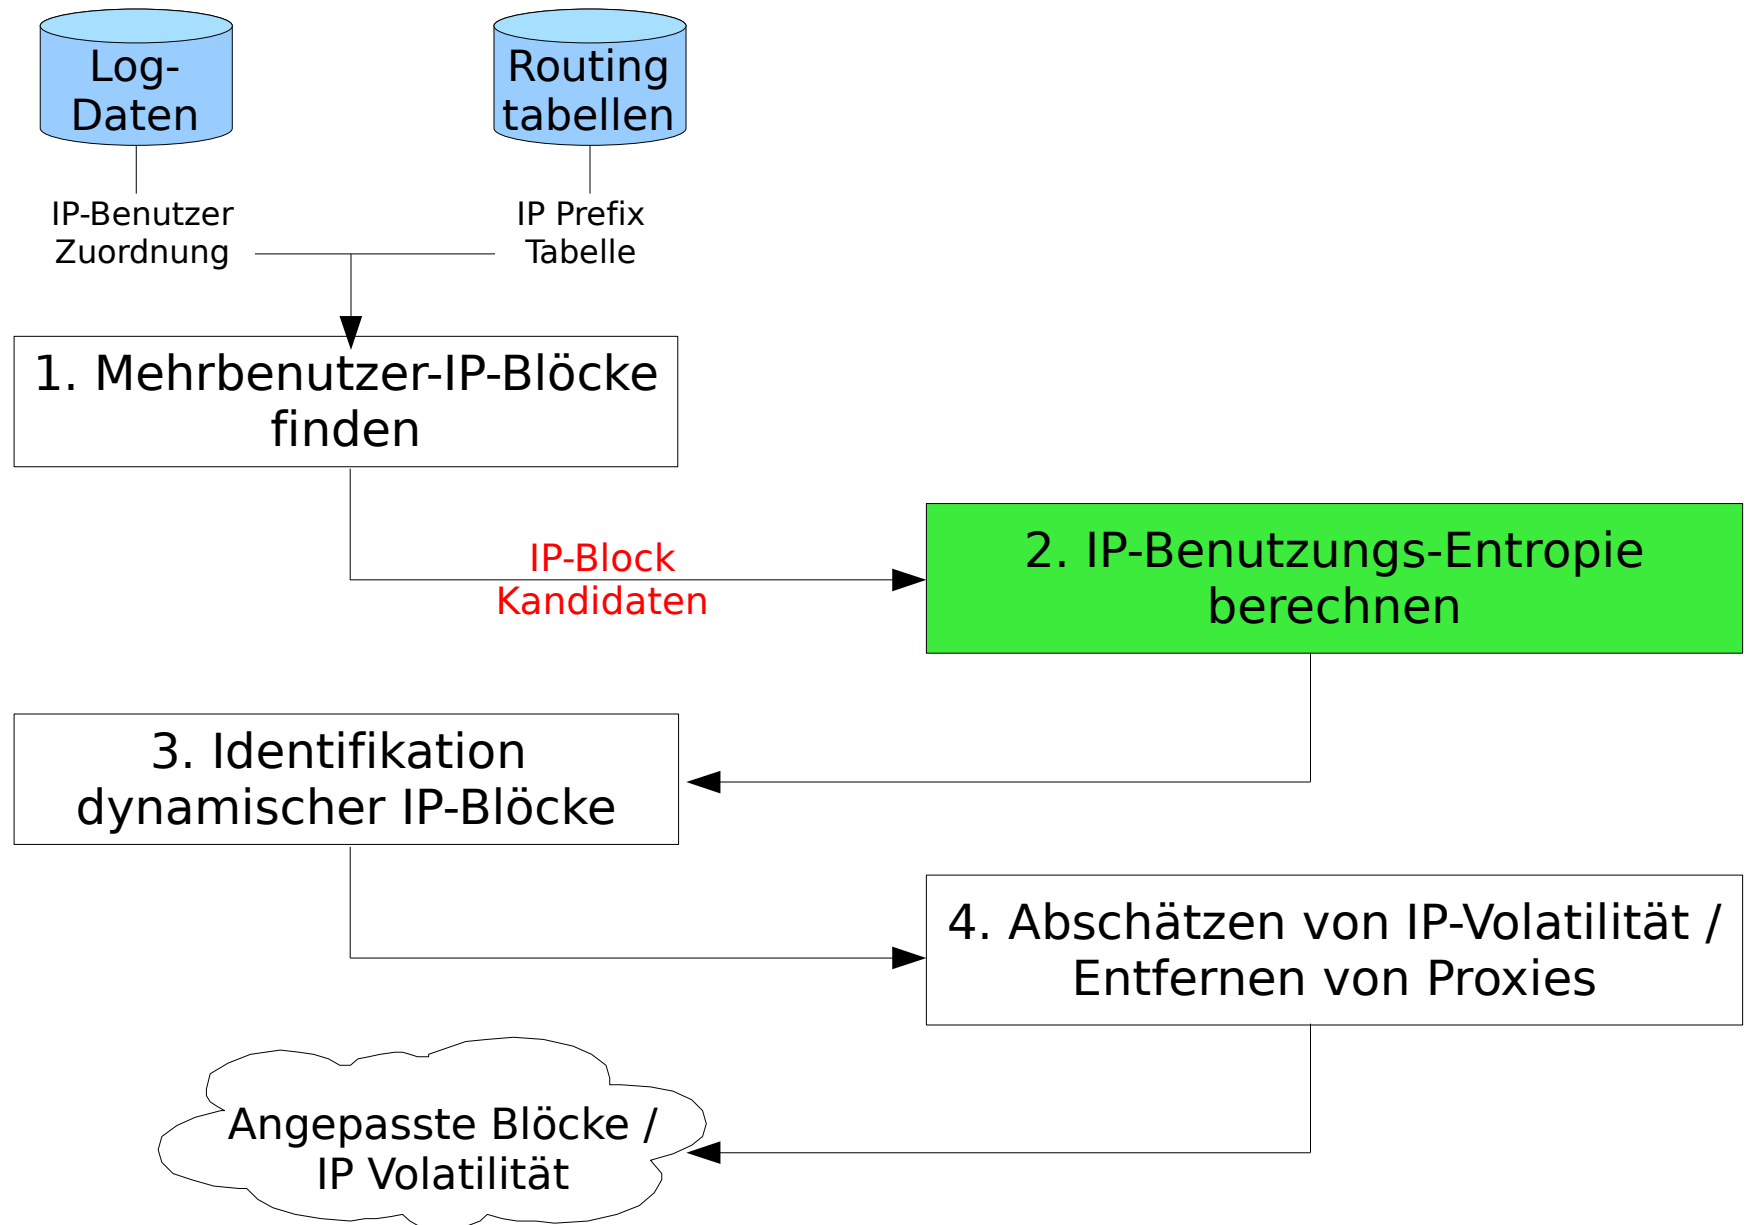


1. Mehrbenutzer-IP Blöcke finden

- mehrere aufeinanderfolgende IPs erscheinen dynamisch
- Kriterien:
 1. alle Adressen haben **gleiches Routing-Prefix**
 2. von m IP-Adressen müssen **mindestens k** Adressen im Log vorhanden und **Lücken nicht größer als g** sein
 3. **Anfangs- und Endadresse** des Blocks müssen im Log auftreten

How dynamic are IP Addresses?

Workflow ← UDmap

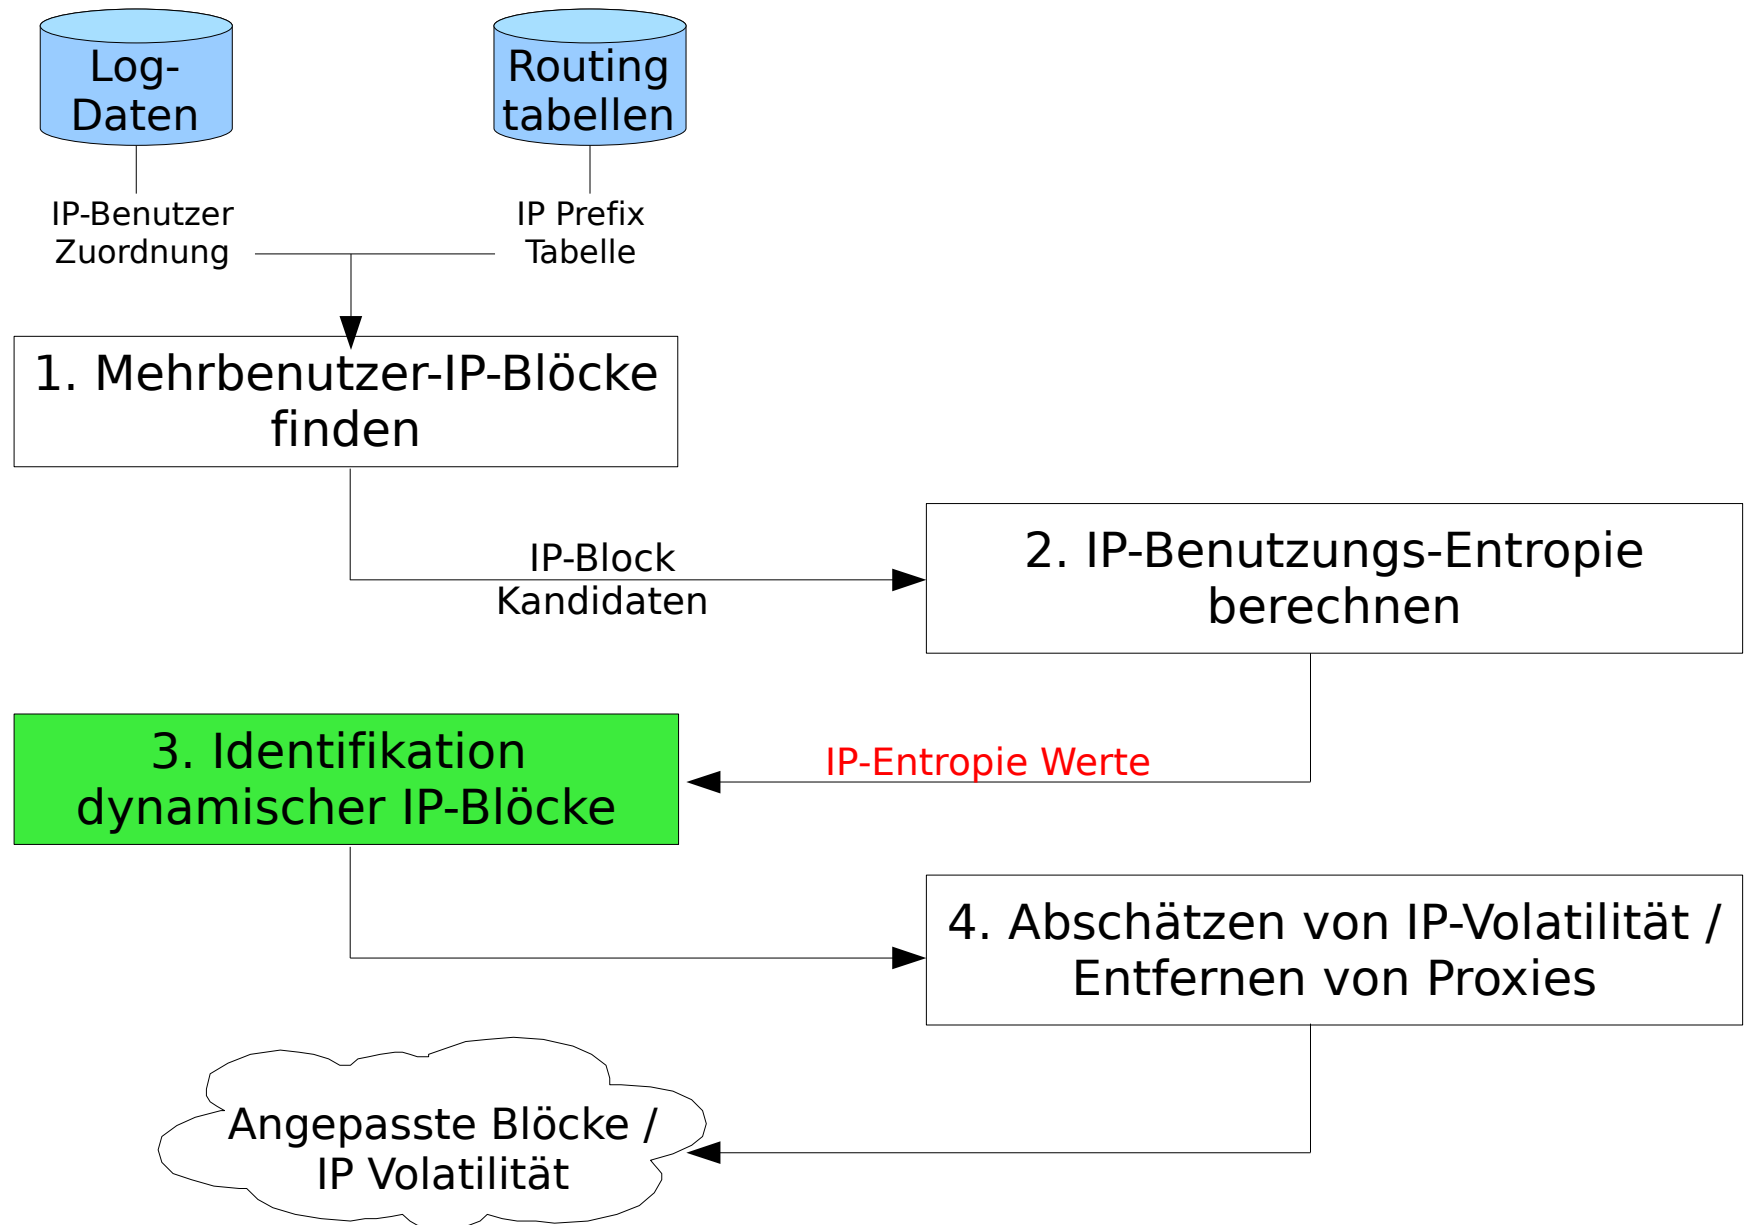


2. IP-Benutzungs-Entropie berechnen

- Ziel: Prüfen, ob einzelne IP-Adressen tatsächlich dynamisch und der Block zusammengehörig ist

How dynamic are IP Addresses?

Workflow ← UDmap

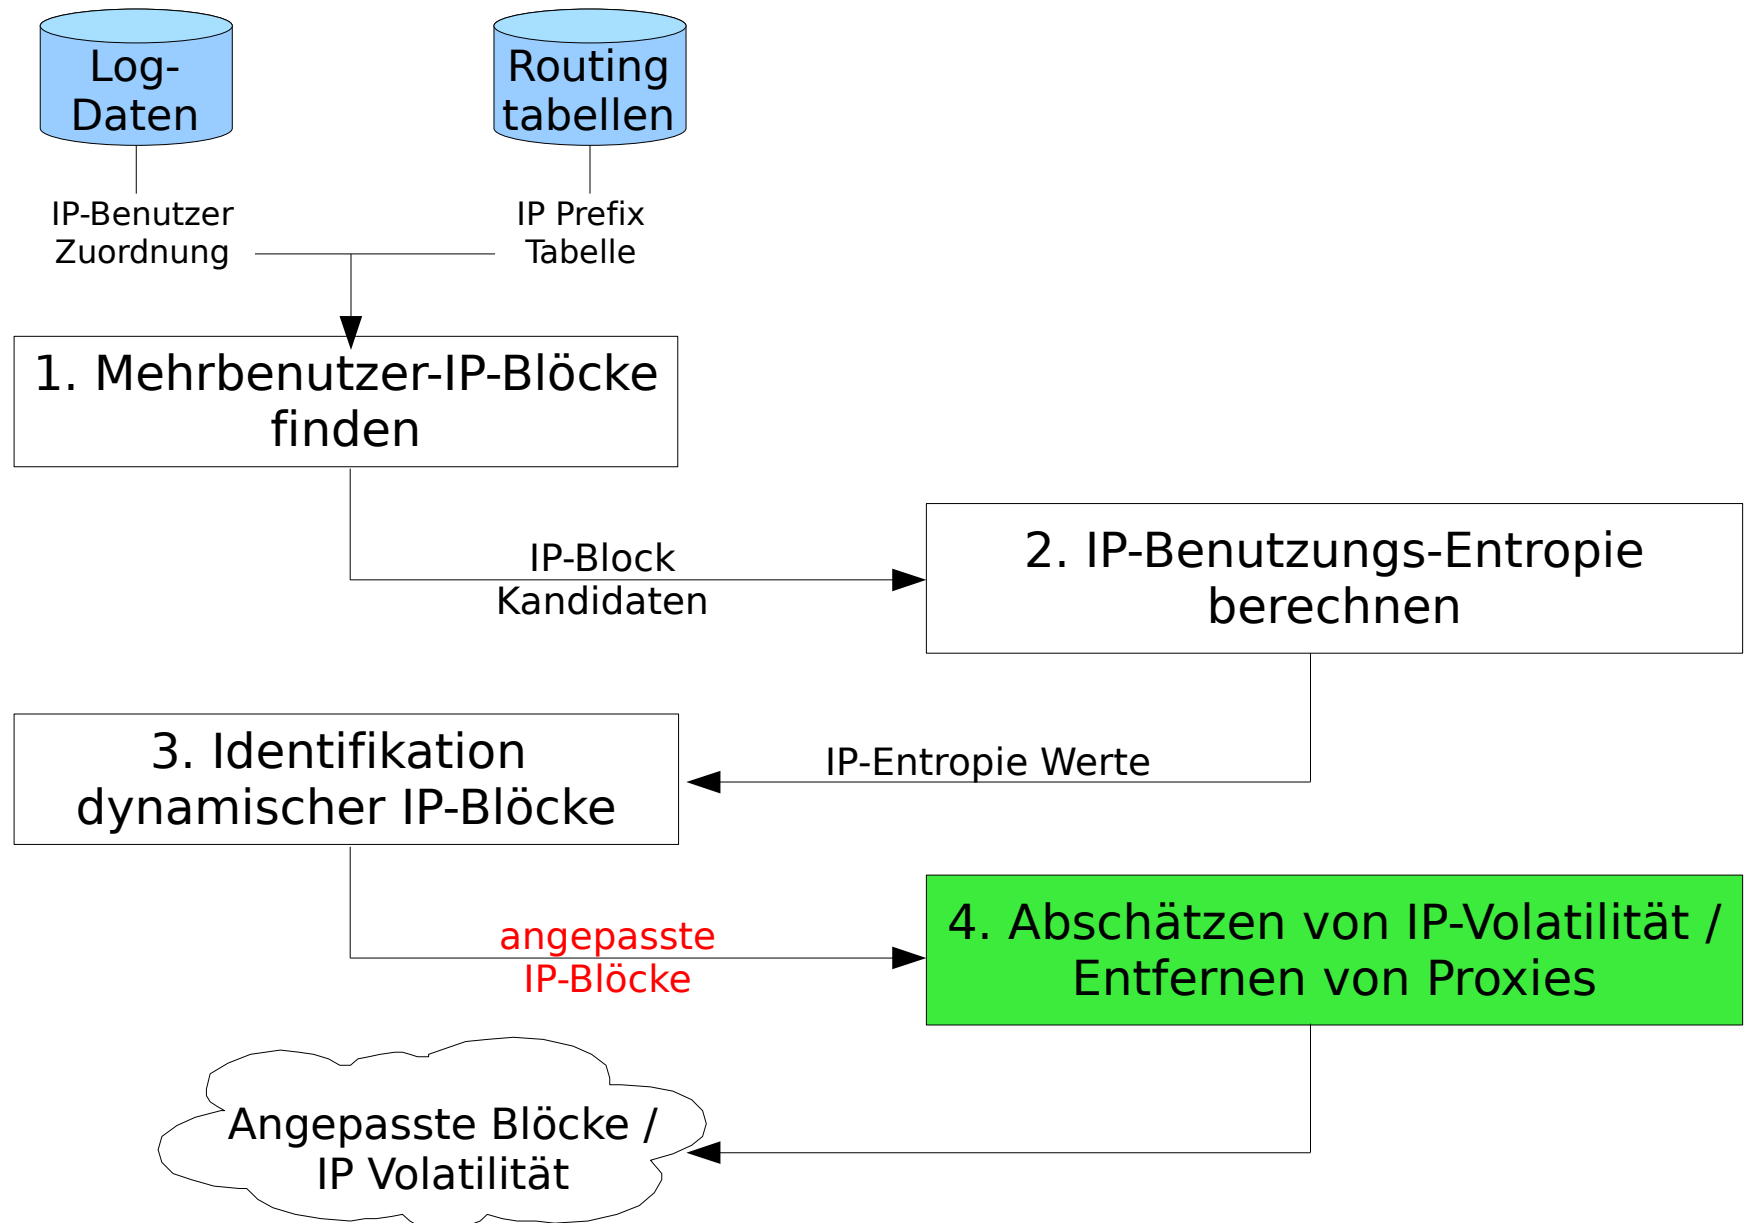


3. Identifikation dynamischer Blöcke

- Block-Kandidaten werden anhand Benutzungsentropie ggf. in Subblöcke unterteilt
- Anwenden der Signalglättungsfunktion

How dynamic are IP Addresses?

Workflow ← UDmap



4. IP-Volatilität, Entfernen von Proxys

- Volatilitätswerte von IP-Adressen innerhalb der jetzt angepassten Blöcke berechnen
- darüber identifizierte Proxies ect. ausschliessen

- **Validierung der Ergebnisse**
 - Abgleich mit Dynablock Blacklisting Tabellen
 - verbleibende Adressen werden über rDNS verifiziert

- **Revision**
 - ohnehin schon gefragtes netzwerk-basiertes Filtern wird noch effizienter
 - könnte langfristig Mailprovider unabhängiger von Blacklisting-Diensten machen
 - Kostenersparnis durch weniger Traffic
 - Erkenntnisse über Charakteristik dynamischer IPs nicht nur für Blacklisting sondern auch Forschung interessant

- Quellen

- How dynamic are IP Addresses?

- Y. Xie, F. Yu, K. Achan, E. Gillum, M. Goldszmidt, T. Wobber
ACM SIGCOMM 2007

- In Conference on Email and Anti-Spam

- A. Ramachandran, D. Dagon, and N. Feamster
ACM 2006

How dynamic are IP Addresses?

O RLY?

Fragen?
(YA RLY!)

2. IP-Benutzungs-Entropie ...

- Jedem IP-Block werden für die gesamte Menge an Benutzern U aus dem Log die Benutzungen markiert:
 $A \in \{0,1\}^{|U| \times m}$ zugeordnet (Adjazenzmatrix)
- Benutzungs-Entropiewert $H(j)$ repräsentiert für alle Benutzer $U(j)$ die Wahrscheinlichkeit, eine andere Adresse aus diesem Block zu erhalten

2. IP-Benutzungs-Entropie ...

- $H(j)$ wird für jeden Benutzer aus $U(j)$ berechnet und wegen der unterschiedlichen Blockgröße, auf einen Wert zwischen 0 und 1 normalisiert
- Dabei wird unterschieden zwischen
 - $H_B(j)$, normalized usage entropy
 - $H_U(j)$, normalized sample usage entropy

2. IP-Benutzungs-Entropie ...

- $H_B(j)$ gibt an, ob die Verteilung der Wahrscheinlichkeit der Benutzer $U(j)$, eine andere IP des Blocks zu erhalten, gleichmäßig verteilt ist ($H_B(j) \rightarrow 1$ für hohe Wahrscheinlichkeit)
 $H_U(j)$ ähnlich wie $H_B(j)$, beschränkt sich aber **ausschliesslich** auf die von $U(j)$ im Block verwendeten Adressen

2. IP-Benutzungs-Entropie ...

- Idealfall: Adressen aus dem betrachteten Block werden zufällig vergeben, $H_B(j)$ ist für die meisten Adressen näherungsweise 1
- In der Realität meistens nicht der Fall, da der im Log betrachtete Zeitraum zu kurz ist, um realistische Verteilung zu erhalten
- Bei begrenzter Datenmenge schätzt $H_U(j)$ die Gleichverteilung der Adressauswahl besser ab