

インターネット計測とデータ解析 第2回

長 健二郎

2010年10月6日

前回のおさらい

本授業のテーマ

- ▶ いろいろな切口からインターネットの実態を考える
 - ▶ 容易に計測できないものをどう計るか
 - ▶ 大量データからいかに情報を抽出する

ネットワーク計測とインターネット計測
ネットワーク管理ツール

今日のテーマ

インターネットのサイズを計る

- ▶ ユーザ数、ホスト数
- ▶ ウェブページ数
- ▶ DNS の仕組み、IP アドレス割り当ての仕組み
- ▶ 精度 誤差 有効数字


最近の話題

国勢調査

- ▶ 人口統計の基礎データ
- ▶ 5年に一度の全数調査
 - ▶ 全数調査の意義
 - ▶ 人口推計の基準となる数値
 - ▶ 標本調査を設計する際の基礎データ
- ▶ 住民基本台帳人口と国勢調査人口

インターネットのユーザ数 (日本)

- ▶ 総務省 通信利用動向調査
 - ▶ 9408 万人 人口普及率 78.0% (2009 年末)
 - ▶ 無作為抽出アンケート方式
 - ▶ 地域及び都市規模を層化基準とした層化二段抽出
 - ▶ 世帯調査 サンプル数 6,256 世帯 有効回答数 4,547
 - ▶ ちなみに全国世帯数 5336 万 (2010/03)
- ▶ 総務省 ブロードバンド契約数
 - ▶ 電気通信事業者からの報告
 - ▶ 契約数 3171 万 (2009 年末)




出典: 総務省 ブロードバンド契約数の推移

世界のインターネットユーザ数

- ▶ 世界 19.7 億人 人口比普及率 28.7% (2010/06)

Internet Users in the World Distribution by World Regions - 2010



Source: Internet World Stats - www.internetworldstats.com/stats.htm


Basis: 1,966,514,816 Internet users on June 30, 2010

Copyright © 2010, Miniwatts Marketing Group

出典: Internet World Stats <http://www.internetworldstats.com/>

アジアのインターネットユーザ数

- ▶ 中国が圧倒的 4.2 億人 人口比普及率 31.6% (2010/06)



Source: www.internetworldstats.com/stats3.htm
Estimated Internet users in Asia 764,435,900 for 2009
Copyright © 2010, Miniwatts Marketing Group

出典: Internet World Stats <http://www.internetworldstats.com/>

インターネットに繋がっている端末数

インターネットに繋がっているという定義は？

- ▶ なんらかの形でインターネット上のデータにアクセスできる
 - ▶ web が見られる
 - ▶ 電子メールが届く
 - ▶ 技術的にはかるのは難しいが、
 - ▶ 2010 年 世界の携帯電話契約数: 50 億
 - ▶ 米 IDC 社調査 2009 年 世界 PC 出荷台数 約 3 億台
- ▶ IP プロトコルで通信できる (NAT の裏側の端末を含む)
- ▶ グローバル IP アドレスを持つ (双方向で IP 通信可能)

ホスト数をはかる

目的

- ▶ インターネットに繋がっているコンピュータ数の把握
 - ▶ NAT の普及で困難
- ▶ IP アドレス利用状況を把握する
 - ▶ IP アドレスは限られた資源
 - ▶ 割り当て (回収) ポリシーへの反映
 - ▶ IPv4 アドレスの枯渇問題

方法


- ▶ DNS から網羅的に調べる
- ▶ IP アドレス空間 (2^{32}) を網羅的に調べる
- ▶ サンプルングして推測
 - ▶ アドレスブロックの利用形態の違いから容易ではない

Domain Name System(DNS)の仕組み (1/3)

JPNIC 「ドメイン名のしくみ」より

▶ <http://www.nic.ad.jp/ja/dom/system.html>

ドメイン名の構成




出典:JPNIC

Domain Name System(DNS)の仕組み (2/3)

DNSの構造

- ▶ root を頂点としたツリー構造
- ▶ 各ドメインには「ネームサーバー」がいてデータベースを分散管理
 - ▶ 配下のドメイン名とIPアドレスの関係を管理
 - ▶ 下位ドメインのネームサーバーへの参照管理




ドメイン名空間 出典:JPNIC

Domain Name System(DNS)の仕組み (3/3)

DNSにおける名前解決の方法


- ▶ 名前解決: ドメイン名を対応する IP アドレスに変換
 - ▶ 逆引き: IP アドレスをドメイン名に変換 (逆引きツリー)



名前解決の流れ (`www.example.co.jp` の例) 出典: JPNIC

IPアドレスの割り当て管理


▶ IANA → RIR → NIR → LIR



IP アドレス管理の階層構造 出典:JPNIC

IPv4 アドレス在庫の枯渇

- ▶ APNIC の Geoff Huston の予測
 - ▶ /8 blocks red:IANA, green:RIR




IPv4 アドレス在庫枯渇予測 出典:<http://ipv4.potaroo.net/>

古典的なホスト数推計方法

The ISC Domain Survey (DNS による調査)

▶ 6.8 億ホスト (2009/07)



出典: ISC domain survey <http://www.isc.org/solutions/servey>

The ISC Domain Survey

計測方法

- ▶ 1987-1997:DNS に登録されたホスト数をカウント (RFC1296)
 - ▶ DNS の委譲ツリーを辿って、各ゾーンからゾーンデータ転送を試みる
 - ▶ ゾーンデータ中の「A レコード」を数える
 - ▶ ゾーンデータ転送を許可しない分を補正するため、ゾーン転送の成功率を使う
- ▶ 1998-:DNS に登録されたユニークな IP アドレス数をカウント
 - ▶ 逆引きの委譲ツリーを辿って、存在する /24 を見つける
 - ▶ 見つかった /24 の全ての IP アドレス (1-254) を逆引きし「PTR レコード」の登録があるか調べる
 - ▶ PTR レコードがあるが存在しないホストがあるため、発見したアドレスの 1%をランダムサンプリングして ping、成功率を補正に使う

制約

- ▶ DNS に登録されていないものはカウントされない
- ▶ DNS に登録だけされて存在しないホストの補正精度
- ▶ NAT の背後にいるホスト数はカウントできない

IP アドレス空間の網羅的調査


- ▶ Heidemann らの 2006/11 の計測データ
- ▶ 割り当て済みの IP アドレス全てに ping
- ▶ 調べたアドレスの 93% は応答なし (firewall, etc)

address type	number	% of addrs	% of probed
IPv4 addresses	4,290M	100%	
reserved	1,160M	27%	
allocated	3,140M	73%	
unprobed (mcast, etc)	342M	8%	
probed	2,800M	65%	100%
replies	187M	4.4%	6.7%
positive replies	103M	3.6%	3.7%
negative replies	84M	2.0%	3.0%
non-replies	2,610M	61%	93%

J. Heidemann, Y. Pradkin, R. Govindan, C. Papadopoulos, G. Bartlett, J. Bannister.
Census and survey of the visible internet.

ACM IMC'08. pp169-182. Vouliagmeni, Greece. October 2008.

IP アドレス空間の利用状況の可視化



<http://www.isi.edu/ant/address/>

ウェブページ数をはかる


- ▶ ウェブページの定義? 動的ページ (calendar, etc) が増加
- ▶ crawling robot によりデータ収集可能
 - ▶ 人気サイトから始めてリンクを辿る
- ▶ 大規模検索システムはある程度情報を持っている、公開はされていない
- ▶ netcraft: web server survey 227 million sites in 2010/09
- ▶ google: indexed 1 trillion (10^{12}) unique URLs in 2008
 - ▶ <http://googleblog.blogspot.com/2008/07/we-knew-web-was-big.html>

正確度と精度、誤差

正確度 (accuracy): 測定値と真値とのずれ

精度 (precision): 測定値のばらつきの幅

誤差 (error): 真値からのずれ、その不確かさの範囲



いろいろな誤差

測定誤差

- ▶ 系統誤差 (条件を把握できれば補正可能)
 - ▶ 器械的誤差、理論的誤差、個人的誤差
- ▶ 偶然誤差 (ノイズ、観測を繰り返せば精度向上)

計算誤差

- ▶ まるめ誤差
- ▶ 打ち切り誤差
- ▶ 情報落ち
- ▶ 桁落ち
- ▶ 誤差の伝搬

サンプリング誤差

- ▶ 標本調査を行う場合、普通は真値は不明
- ▶ 標本誤差: 真値との差の確率的なばらつきの幅

有効数字と有効桁数

1.23 の有効数字は 3 桁 ($1.225 \leq 1.23 < 1.235$)
表記

表記	有効桁数	
12.3	3	
12.300	5	
0.0034	2	
1200	4	(あいまい、 1.200×10^3)
2.34×10^4	3	

計算

- ▶ 計算途中は桁数が大きいまま計算
 - ▶ 筆算などの場合は 1 桁多く取ればよい
- ▶ 最終的な数字に有効桁数を適用

基本ルール

- ▶ 加減算: 桁数が少ないものに合わせる
 - ▶ $1.23 + 5.724 = 6.954 \Rightarrow 6.95$
- ▶ 乗除算: もとの有効数字が最も少ないものに合わせる
 - ▶ $4.23 \times 0.38 = 1.6074 \Rightarrow 1.6$

コンピュータの計算精度

- ▶ integer (32/64bits)
 - ▶ 32bit signed integer (2G までしかカウントできない)
- ▶ 32bit floating point (IEEE 754 single precision): 有効桁数 7
 - ▶ sign:1bit, exponent:8bits, mantissa:23bits
 - ▶ $16,000,000 + 1 = 16,000,000!!$
- ▶ 64bit floating point (IEEE 754 double precision): 有効桁数 15
 - ▶ sign:1bit, exponent:11bits, mantissa:52bits

まとめ

第2回 インターネットのサイズを計る

- ▶ ユーザ数、ホスト数
- ▶ ウェブページ数
- ▶ DNS の仕組み、IP アドレス割り当ての仕組み
- ▶ 精度 誤差 有効数字

次回予定

第3回 インターネットの構造を計る (10/13)

- ▶ インターネットアーキテクチャ
- ▶ ネットワーク階層
- ▶ 経路制御
- ▶ トポロジー
- ▶ グラフ理論