

全世界の Web ページの TLD・言語分布解析

平手 勇宇[†] 山名 早人[‡]

早稲田大学大学院理工学研究科[†] 早稲田大学理工学術院[‡]

1.はじめに

我々は、インターネット情報知識集約を可能にするプラットフォーム構築を目指し、2004 年 1 月下旬から 2006 年 7 月までの約 30 ヶ月の期間に、約 144 億ページの Web ページの収集を行った¹。収集した全世界の Web ページ解析をするにあたり、ページデータセットの全体傾向を把握することは、Web ページ解析結果を向上させるために重要である。この目的のため、我々は収集した Web ページの統計的な調査を行っている。本稿では、データとして利用可能な 107 億ページ²の Web ページを対象とし、トップレベルドメイン(以下 TLD とする)、記述されている言語の 2 つの切り口で調査を行った結果を報告する。

2.107 億ページの TLD・言語分布状況

2004 年 1 月 9 日から 2006 年 7 月 31 日の期間に収集された約 144 億ページの内、10,696,996,553 ページに対して解析を行った。なお、Web ページの収集の際に、Basis Technology の Rosette 言語判定システム³を利用し、当該 Web ページがどのような言語で記述されているのかの言語判定を行っている[1]。本節では、約 107 億ページの TLD 分布、言語分布について示す。

収集した約 107 億ページの TLD 分布を表 1 に示す。全世界には合計 272 個存在する[2]が、表 1 では、取得ページ数が多かった TLD 上位 15 個、および 16 位以下の TLD の合計を Other としてまとめ上げた。表 1 より、“.com”に属する Web ページは、全体の 38.05% を占めており、Web が “.com”に偏っていることがわかる。また、.com, .net, .org 等の gTLD のドメインに属するウェブページの割合は全体の 56.95% と、全体の半分以上を占めている。

また、国別コードトップレベルドメイン(ccTLD)の中で、一番大きな割合となったのはドイツ(8.22%)であった。TLD 上位 15 位中の ccTLD が対応する国は、ロシア・ポーランド・中国を除き、全てインターネット普及率が 2007 年 6 月現在 50% 以上[3]であった。

図 1 に収集した 107 億ページの言語分布を示す。なお図 1 の判例の bin は、画像等のバイナリであることを意味する⁴。図 1 に示す通り、英語で書かれたページが、全体の 42.57% を占めている。次に多かった言語は日本語の 13.00% であるが、これは我々が日本語ページを起点として Web ページを収集したため、我々の Web ページクローラー

表 1: 全収集ページの TLD 分布			
TLD	国名(ccTLD のみ)	取得ページ数	割合
.com	-	4,070,092,124	38.05%
.net	-	890,604,259	8.33%
.de	ドイツ	878,838,449	8.22%
.org	-	745,984,032	6.97%
.jp	日本	543,654,556	5.08%
.ru	ロシア	407,169,769	3.81%
.pl	ポーランド	321,209,334	3.00%
.uk	イギリス	240,244,507	2.25%
.edu	-	232,132,978	2.17%
.nl	オランダ	215,722,380	2.02%
.cn	中国	185,907,711	1.74%
.it	イタリア	156,657,707	1.46%
.kr	韓国	151,025,640	1.41%
.us	アメリカ	143,135,686	1.34%
.fr	フランス	129,326,495	1.21%
other	-	1,385,290,926	12.95%

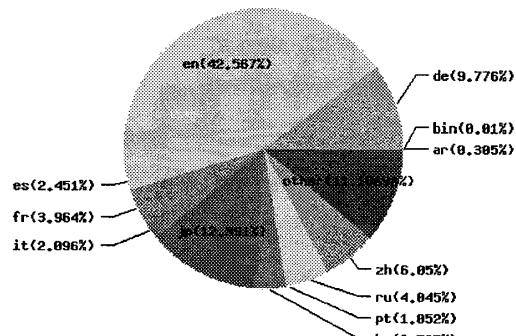


図 1: 全収集ページの言語分布

リングが、日本語に偏っていることが原因であると考えられる。

3. TLD 每の言語分布解析

次に、収集したページを TLD ごとに分類し、TLD ごとに言語割合を計算し、当該国のインターネット普及率[3]と比較する⁵ことで、TLD 每の言語分布解析を行った。紙面の都合上、全 TLD の結果を示すことができないため、本稿では一部の TLD のみ記載を行う⁶。

表 2 では、TLD ごとの収集した Web ページの言語分布、およびインターネット普及率を示したものである。.com ドメイン、.net ドメインの 2 つの TLD は、一般 TLD (=gTLD) でかつ Web ページ数が多いため、Web 全体の言語分布と似た言語分布となる結果であった。

¹ 2007 年 9 月以降は、日本語 Web ページを含むホストを対象に、更新 Web ページの収集を目的として、取得済みのホストに含まれる Web ページの再収集を行っている。

² 37 億ページは DISK 故障等によりデータが失われた。

³ アラビア語(ar), ドイツ語(de), 英語(en), スペイン語(es), フランス語(fr), イタリア語(it), 日本語(jp), 韓国語(kr), ポルトガル語(pt), ロシア語(ru), 中国語(zh), バイナリ(bin), その他に判別することが可能である。

⁴ 我々は、バイナリを収集しないポリシーでクローリングを行ったため、実際のバイナリの割合はもっと大きな値となる。

⁵ ccTLD のみを対象とした。

⁶ 全ドメインの言語分布結果は、

<http://www.yama.info.waseda.ac.jp/e-society/>を参照のこと。

表 2: ccTLD ごとの言語分布率、収集ページ数、公用語およびインターネット普及率

ccTLD	国名	ar	bn	de	en	es	fr	it	jp	ko	pt	ru	zh	その他	収集ページ数	公用語	普及率
.com	-	0.5 5%	0.0 0%	2.9 7%	47. 77%	3.8 2%	5.1 0%	1.2 9%	18. 29%	4.4 6%	0.5 1%	0.4 3%	8.5 5%	6.27 %	4,070,092,124		
.net	-	0.5 9%	0.0 0%	4.1 0%	55. 67%	1.7 9%	3.3 6%	2.1 6%	13. 03%	3.6 4%	0.3 8%	0.9 9%	8.1 8%	6.10 %	890,604,259		
de	ドイツ	0.0 3%	0.0 1%	85. 50%	10. 04%	0.2 5%	0.4 5%	0.3 7%	0.0 6%	0.0 2%	0.0 9%	0.1 7%	0.0 8%	2.93 %	878,838,449	de	64.6 %
jp	日本	0.0 0%	0.0 0%	0.1 3%	5.9 2%	0.0 8%	0.1 8%	0.0 9%	90. 28%	0.0 5%	0.0 3%	0.0 1%	0.2 6%	2.97 %	543,654,556	jp	68.0 %
ch	スイス	0.0 4%	0.0 1%	51. 12%	29. 41%	0.5 6%	11. 41%	2.5 8%	0.1 1%	0.0 2%	0.1 6%	0.1 4%	0.2 4%	4.19 %	55,544,767	de, fr, it	69.2 %
it	イタリア	0.0 6%	0.0 4%	1.5 9%	15. 82%	0.6 1%	0.6 8%	78. 48%	0.0 6%	0.0 2%	0.2 0%	0.1 4%	0.1 5%	2.24 %	156,657,707	it	57.0 %
kr	韓国	0.0 0%	0.0 0%	0.0 6%	4.2 1%	0.0 2%	0.1 9%	0.0 4%	94. 8%	0.0 14%	0.0 1%	0.0 1%	0.0 8%	1.15 %	151,025,640	kr	67.1 %
fr	フランス	0.0 1%	0.0 3%	0.6 2%	16. 71%	0.5 5%	76. 18%	0.4 6%	0.0 8%	0.0 1%	0.1 7%	0.0 5%	0.0 8%	5.03 %	129,326,495	fr	54.7 %
ru	ロシア	0.0 1%	0.0 2%	0.2 5%	9.6 2%	0.0 7%	0.1 5%	0.0 8%	0.0 2%	0.0 1%	0.0 3%	87. 70%	0.0 3%	2.00 %	407,169,769	ru	19.5 %
cn	中国	0.1 1%	0.0 0%	0.1 1%	5.1 5%	0.1 1%	0.1 5%	0.1 2%	0.2 7%	0.0 1%	0.0 2%	0.1 16%	91. 16%	2.62 %	185,907,711	zh	12.3 %
to	トンガ	0.0 0%	0.0 0%	2.9 37%	17. 4%	0.1 4%	1.5 4%	0.6 6%	59. 20%	0.6 4%	0.0 4%	0.5 3%	14. 77%	2.22 %	4,623,520	トンガ語 en	3.0 %
dj	ジブチ	0.0 3%	0.0 0%	75. 91%	11. 24%	0.2 5%	6.3 1%	0.1 4%	0.1 4%	1.8 5%	0.0 2%	3.5 7%	0.0 0%	0.54 %	211,451	fr	1.4 %
cc	ココス諸島	0.2 6%	0.0 0%	5.7 6%	57. 84%	0.6 1%	0.7 6%	2.8 8%	20. 00%	1.8 9%	0.1 0%	0.2 4%	7.5 7%	2.12 %	24,599,794	en	n/a

3.1 インターネット普及率が高い国

インターネット普及率が 50%以上と高い国は全部で 37 カ国存在する。これらの国が該当する ccTLD の全 Web ページのうち、おおよそ 7 割以上が母国語で書かれていた [4]。

例外は、スイス、ガーリン島の 2 カ国である。スイスは公用語でない英語ページが全体の 29.41%を占めており、公用語のフランス語、イタリア語よりも大きな割合を占めている。ガーリン島は、フランスに隣接する小さな島国であり、公用語がフランス語・英語であるにもかかわらず、ドイツ語の Web ページの割合が、25.5%を占めていた。これは、ガーリン島が国策としてドメインを売っており、ドイツのサイトが gg ドメインを利用していることが考えられる。

3.2 インターネット普及率が低い国

インターネット普及率が低い国々には、3.1 で示したガーリン島と同じ現象が多く見られる。たとえば、トンガ(.to ドメイン)の公用語は、トンガ語・英語であるにも関わらず、.to ドメインに属する Web ページのうち、日本語のページが 59.2%の割合であった。また、ジブチ(.dj ドメイン)では、ドイツ語が 75.91%も占めており、これはジブチ在住の人を対象にしたページとは考えにくい。ココス諸島 (.cc ドメイン) に関しても、公用語でない日本語のページが目立つ⁷。

このような現象は、インターネット普及率が低く、かつ面積が非常に小さな国で頻発する。このほかにも、ア

⁷ ココス諸島では、公用語ではないが中国語も利用されている [4]。

センション島(.ac)、ベリーズ(.bz)、クリスマス諸島(.cx)、ミクロネシア連邦(.fm)、グレネダ(.gd)、サウスジョージア・サウスサンドウェイッチ諸島(.gs)、イギリス領インド洋地域(.io)、ペルトリコ(.pr)、セントヘレナ(.sh)、サントメ・プリンシペ(.st)、ツバル(.tv)等が挙げられる。

4.おわりに

本稿では、全世界の Web ページ約 107 億ページを対象として、Web 全体の傾向調査、および TLD、言語の二つの切り口から、Web の傾向の調査を行った。

Web 全体では、.com に属する Web ページが全体の 38.05%と偏っていた。また、国別に、Web ページの言語分布状況を調べた結果、インターネット普及率が高い国々では、おおよそ当該公用語で書かれた Web ページが大きな割合を占める結果であった。しかし、普及率が小さく、面積が小さな国々では、ドメインを売る政策の影響のため、公用語でない言語で書かれた Web ページが多数存在している結果となった。

参考文献

- [1] Basis Technology, Rosette 言語判定システム, <http://www.basistech.co.jp/language-identification/>
- [2] IANA, <http://www.iana.org/>
- [3] Internet Usage World Stats - Internet and Population Statistics, <http://www.internetworkworldstat.com/>
- [4] CIA - The World Factbook, <https://www.cia.gov/library/publications/the-world-factbook/>