

Evolução da Distribuição de Conhecimento de Software em Projetos *Open Source*

Talita Santana Orfanó

Orientadoras: Mariza A. da Silva Bigonha e Kécia Aline M. Ferreira

Universidade Federal de Minas Gerais





Diversos estudos apontam uma significativa relação entre os **fatores humanos** e a **qualidade de software**

Contexto

- A **falta de conhecimento** dos desenvolvedores sobre o código fonte em que fazem manutenção
- Popularização de **projetos *open source***
 - Desenvolvimento colaborativo
 - Mineração de dados em repositório públicos
 - **GitHub**, BitBucket, GitLab



Contexto

- **Desenvolvedores *heroes***

- Aqueles poucos que efetuaram a maior parte das contribuições do projeto
- Também conhecidos como *core developer*, *major*, *hero* ou *main developer*

- **Desenvolvedores periféricos**

- A maioria dos desenvolvedores do projeto
 - Realizam poucas contribuições
- Em geral, atuam na evolução de uma pequena funcionalidade ou na correção de *bugs*

Problema

Poucos trabalhos estudam como **a distribuição do conhecimento dos desenvolvedores evolui** no decorrer do ciclo de vida do software

- O conhecimento sobre a evolução da **atuação** dos desenvolvedores ao longo da existência de projetos *open source* ainda não é amplo

Objetivo

Investigar, por meio de estudos de caso, como a distribuição de conhecimento do código evolui ao longo do ciclo de vida do projeto

Questões de Pesquisa (QP)



QP1. O conhecimento do software se difunde ao longo de seu ciclo de vida?

QP2. Os desenvolvedores considerados *heroes* nas primeiras versões permanecem *heroes* durante a evolução do projeto?

QP3. A concentração do conhecimento é impactada pela quantidade total de contribuições do projeto?

Questões de Pesquisa (QP)



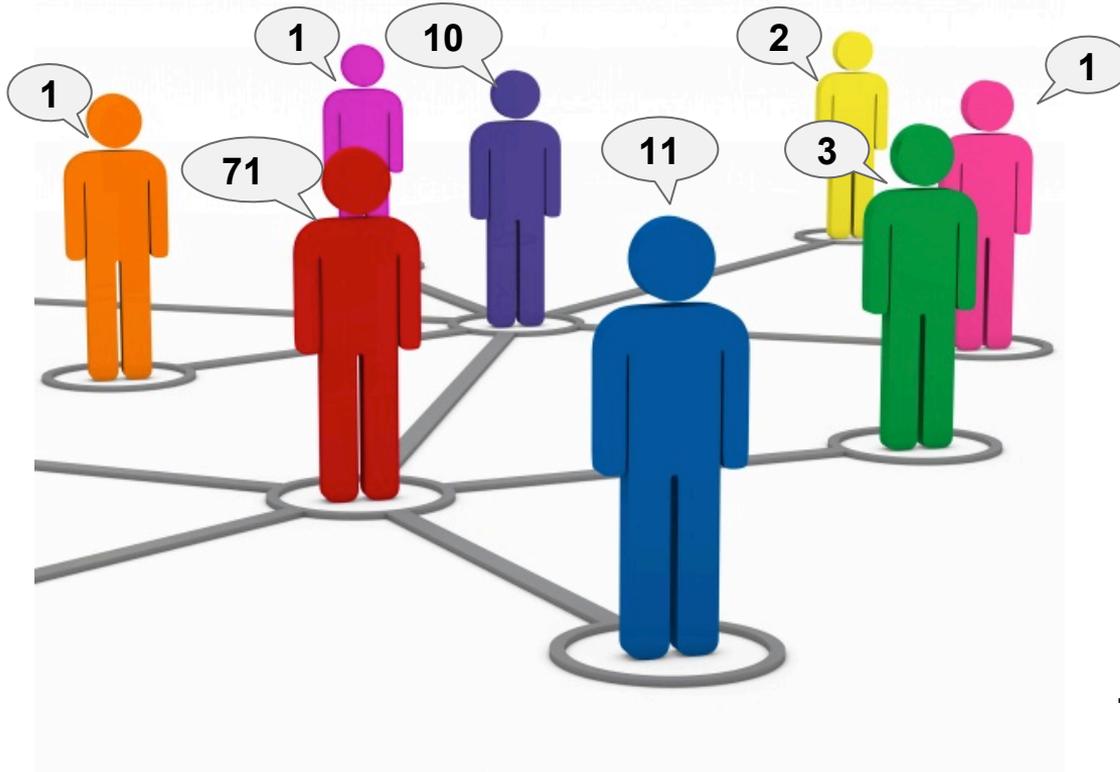
QP4. Como se dá a atuação dos desenvolvedores periféricos nos projetos?

QP5. Como ocorre a disseminação de conhecimento do software entre os desenvolvedores?

Propriedade de Código

- **Principais trabalhos**
 - DOK (*degree-of-knowledge*)
 - Fritz et al., 2014
 - Linhas alteradas como fator de medição da autoria
 - Rahman & Devanbu, 2011
 - Proprietário do módulo
 - **Bird et al., 2011 e Foucault et al., 2014**
 - Métrica *Truck Factor*
 - Torchiano et al., 2011 e Avelino et al., 2016

Propriedade de Código



Total de 100 *commits*

Propriedade de Código



Metodologia

1. Coleta de Dados



2. Tratamento de dados e desambiguação



3. Caracterização de Dados



4. Survey



5. Análise e Discussão dos Resultados



Coleta de Dados

Bootstrap, Django, Elasticsearch, Panda e Spring Boot

+119.500

commits

+6.900

autores

+850

releases

Coleta de Dados

- **Granularidade por *commits***
 - Não há um consenso na literatura sobre a melhor maneira de avaliar autoria e contribuição, especialmente em projetos *open source*
 - Custo para processar, armazenar e analisar grande gama de informações geradas por coletas de granularidades menores é muito alto
 - Vários trabalhos relacionados utilizaram a granularidade de *commits*

Coleta de Dados

- **Ferramenta para coleta**

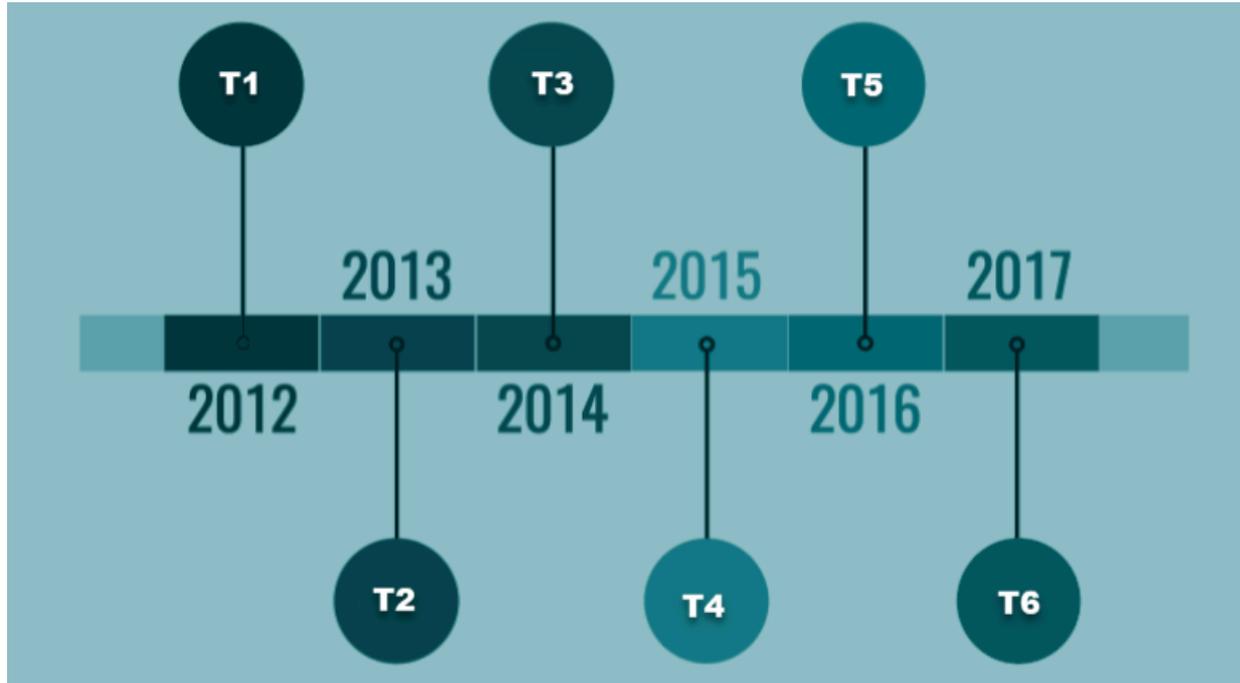
- Dados coletados utilizando a API REST do GitHub
- Facilidade de utilização e ampla documentação
- Completude das informações coletadas diariamente dos repositórios originais
- Resultados obtidos no formato *JSON*

Coleta de Dados

- **Solução construída**
 - Construídos *scripts* em *Python*
 - Para coleta dos dados via API REST do GitHub
 - Dados coletados armazenados
 - MongoDB e arquivos *CSV*
 - Conjunto de dados coletados
 - código identificador do *commit* (*sha*),
 - informações do contribuidor (nome, e-mail e *login*)
 - data do *commit* e nome do repositório
 - Primeiro *commit* de cada projeto até 2019/1

Coleta de Dados

Janela de Tempo



Coleta de Informações

- **Contribuições por autor**
 - Total de *commits* efetuados por cada autor
 - Identificar quais autores mais contribuíram no repositório desde a sua criação
 - Compreender como é distribuído o total de *commits* entre os contribuidores dos projetos

Coleta de Informações

- **Contribuições por período de tempo T**
 - Total de *commits* efetuados por cada autor em cada período T
 - Compreender como as contribuições cresceram ou diminuíram no decorrer do ciclo de vida do projeto
 - Entender o processo de distribuição de conhecimento entre os autores no ciclo evolutivo
 - Analisar o processo de evolução dos autores considerados *heroes* do projeto

Desambiguação de Autores

- Em projetos *open source* é frequente a existência de contribuidores ambíguos
- Usuários que no mesmo projeto utilizam nomes ou e-mails diferentes
 - Identificados erroneamente como sendo duas ou mais pessoas distintas
- Essas particularidades, se não tratadas, podem impactar os resultados dos estudos

Desambiguação de Autores

- **Por login**
- **Nome e e-mail - Por heurísticas**
 - Algoritmo de similaridade Bird [Bird et al., 2006]
 - Alto coeficiente de revocação (*recall*) - 100%
 - Baixa precisão em projeto de grande porte - ~30%
- **Nome e e-mail - Manual**
 - Solução adotada

Desambiguação de Autores

- **Por nome / e-mail - Manual**

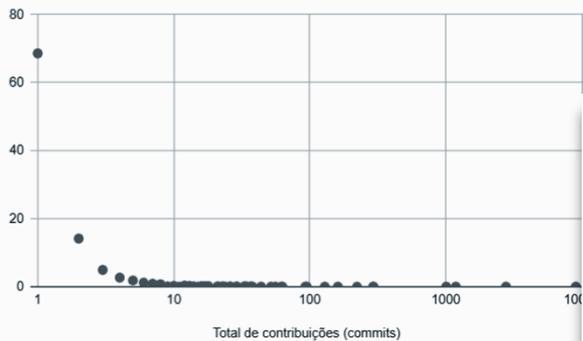
- Processo custoso, porém com maior precisão e confiabilidade
 - Autores ambíguos que trariam **grande impacto** nos resultados: *heroes*, médios e pequenos que possuíam grande número de contribuições
 - Nomes e e-mails ordenados alfabeticamente e comparados entre si
 - Nomes ou e-mails iguais foram unificados
 - Nomes ou e-mails semelhantes foram avaliados individualmente com o auxílio de pesquisas externas

Evolução da Distribuição do Conhecimento Entre os Desenvolvedores

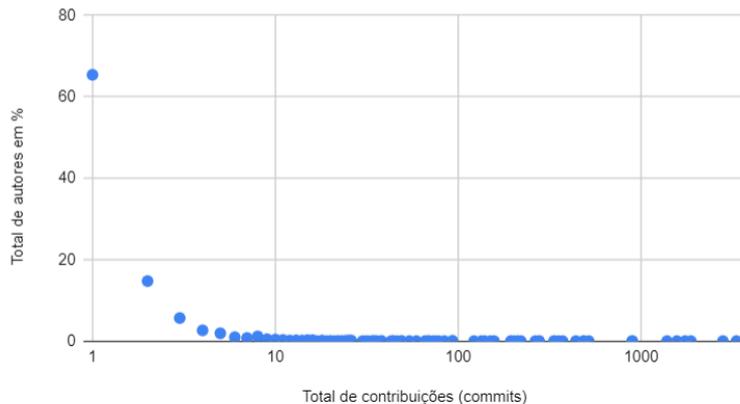


Distribuição da População de Autores

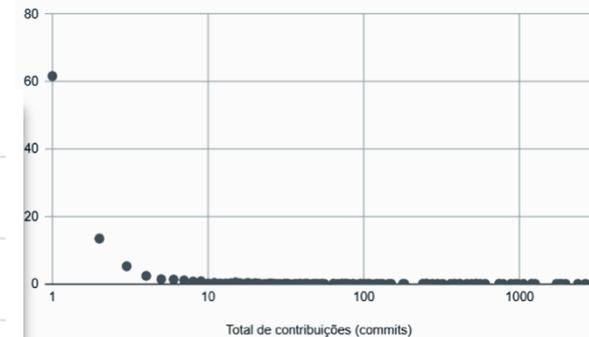
Distribuição de Autores - Bootstrap



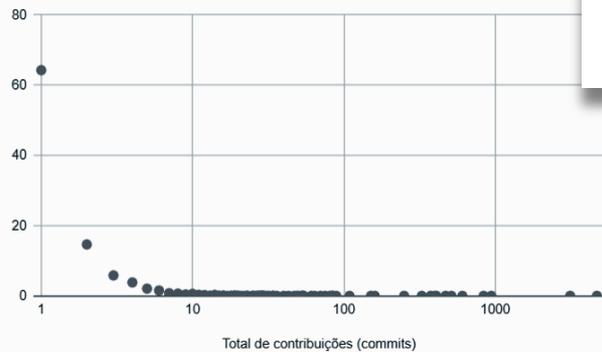
Distribuição de Autores - Django



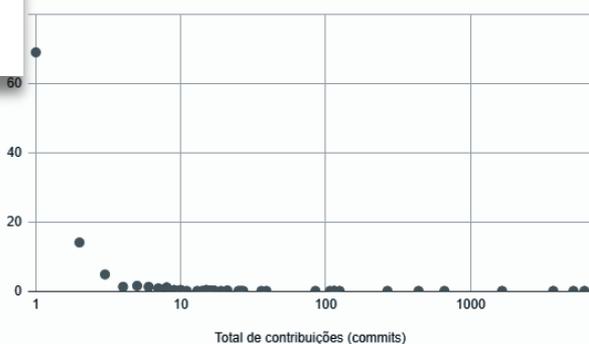
Distribuição de Autores - Elasticsearch



Distribuição de Autores - Panda



Distribuição de Autores - Spring Boot



Distribuição da População de Autores

- A maior parcela de autores realizaram poucas contribuições
 - Ao menos 80% dos autores realizaram apenas 2 contribuições
- A distribuição da população de autores possui cauda longa
 - Quantidade de autores diminui exponencialmente e torna-se mais esparsa
 - Poucos desenvolvedores realizam uma quantidade alta de contribuição nos repositórios
- Conhecimento concentrado em poucos contribuidores
- Comportamento homogêneo em todos os projetos do *data set*
- Resultado em concordância com trabalhos prévios
 - Avelino et al., 2019b; Greiler et al., 2015; Foucault et al., 2014; Ricca & Marchetto, 2010

Caracterização da População de Autores

- Diferença na atuação dos autores em um projeto *open source*
 - Necessidade de estudá-los de forma segmentada
- **Heroes:**
 - Soma das contribuições é maior ou igual a 5% do total do projeto
- **Médios:**
 - Soma das contribuições é maior ou igual a 1% e menor que 5%
- **Periféricos:**
 - Soma das contribuições é menor que 1%

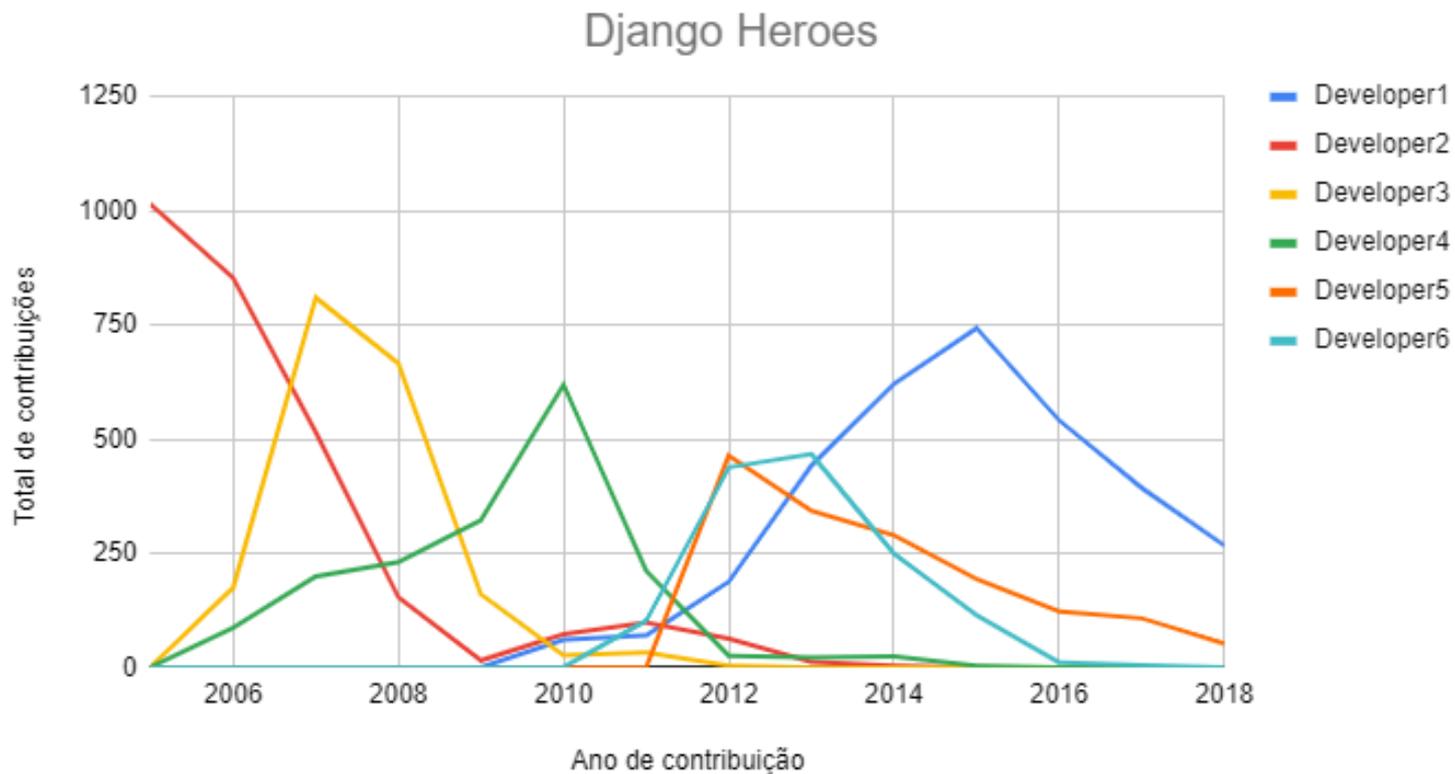
Caracterização da População de Autores

| Projeto | Categoria | Σ autores | Σ <i>commits</i> | Percentual de contribuição (%) |
|----------------------|--------------------|------------------|-------------------------|--------------------------------|
| <i>Bootstrap</i> | Autor periférico | 1.278 | 3.579 | 19,49 |
| | Autor médio | 3 | 811 | 4,42 |
| | Autor <i>heroe</i> | 4 | 13.969 | 76,09 |
| <i>Django</i> | Autor periférico | 2.065 | 7.869 | 29,70 |
| | Autor médio | 13 | 5.928 | 22,38 |
| | Autor <i>heroe</i> | 6 | 12.694 | 47,92 |
| <i>Elasticsearch</i> | Autor periférico | 1.196 | 8.963 | 24,77 |
| | Autor médio | 21 | 14.870 | 41,09 |
| | Autor <i>heroe</i> | 6 | 12.352 | 34,14 |
| <i>Pandas</i> | Autor periférico | 1.690 | 5.624 | 30,27 |
| | Autor médio | 9 | 4.187 | 22,53 |
| | Autor <i>heroe</i> | 3 | 8.770 | 47,20 |
| <i>Spring Boot</i> | Autor periférico | 664 | 1.970 | 9,86 |
| | Autor médio | 3 | 1.365 | 6,84 |
| | Autor <i>heroe</i> | 4 | 16.618 | 83,3 |

Distribuição dos *Heroes* no Ciclo Evolutivo

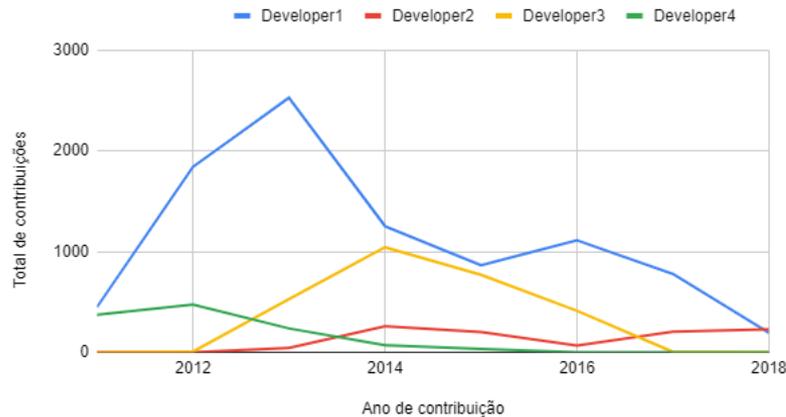
- Concentração expressiva do conhecimento do código nos autores *heroes*
- Finalidade de compreender como as contribuições dos *heroes* evolui
 - Se estão em constante crescimento ou não
 - Se ocorre um rápido pico ou se o aumento das contribuições é gradual

Distribuição dos *Heroes* no Ciclo Evolutivo

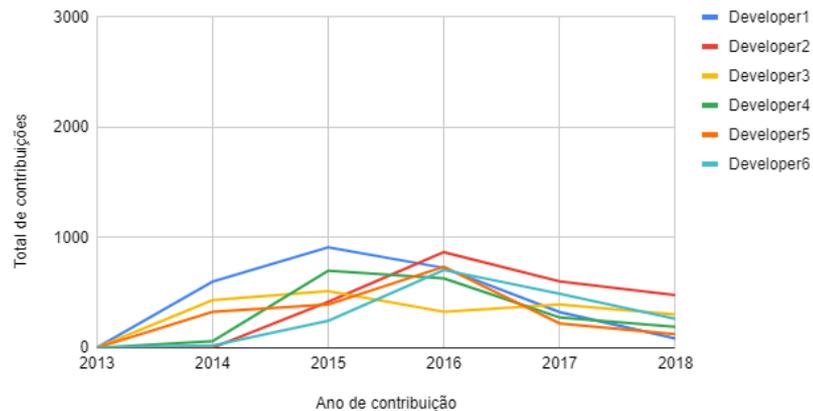


Distribuição dos *Heroes* no Ciclo Evolutivo

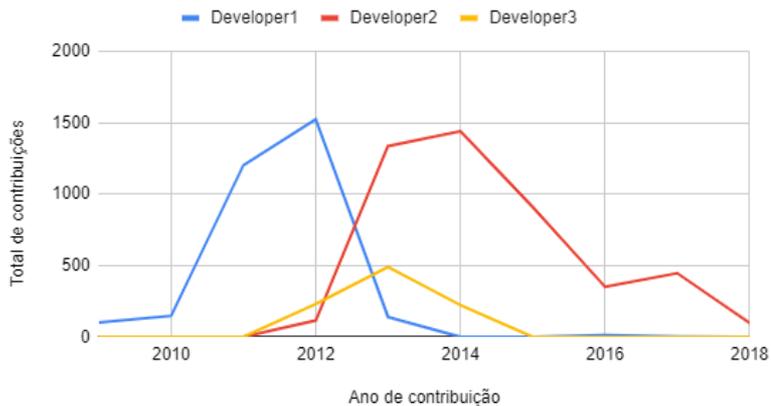
Bootstrap Heroes



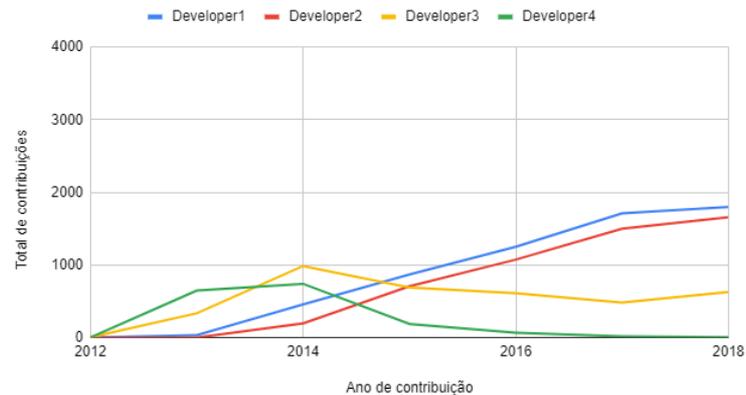
ElasticSearch Heroes



Panda Heroes



Spring Boot Heroes



Propriedade de Código no Ciclo Evolutivo do Software

- Adaptando as notações desenvolvidas por Foucault et al. [2014] para o contexto do presente estudo
- A propriedade de código é dada pela razão das contribuições feitas por um desenvolvedor pelo total das contribuições do projeto

$$own_{p,d} = \frac{\omega(p,d)}{\omega(p)}$$

- O valor mais elevado dessa razão representa a **propriedade de código do projeto** e o desenvolvedor responsável por essa contribuição é considerado o **proprietário**

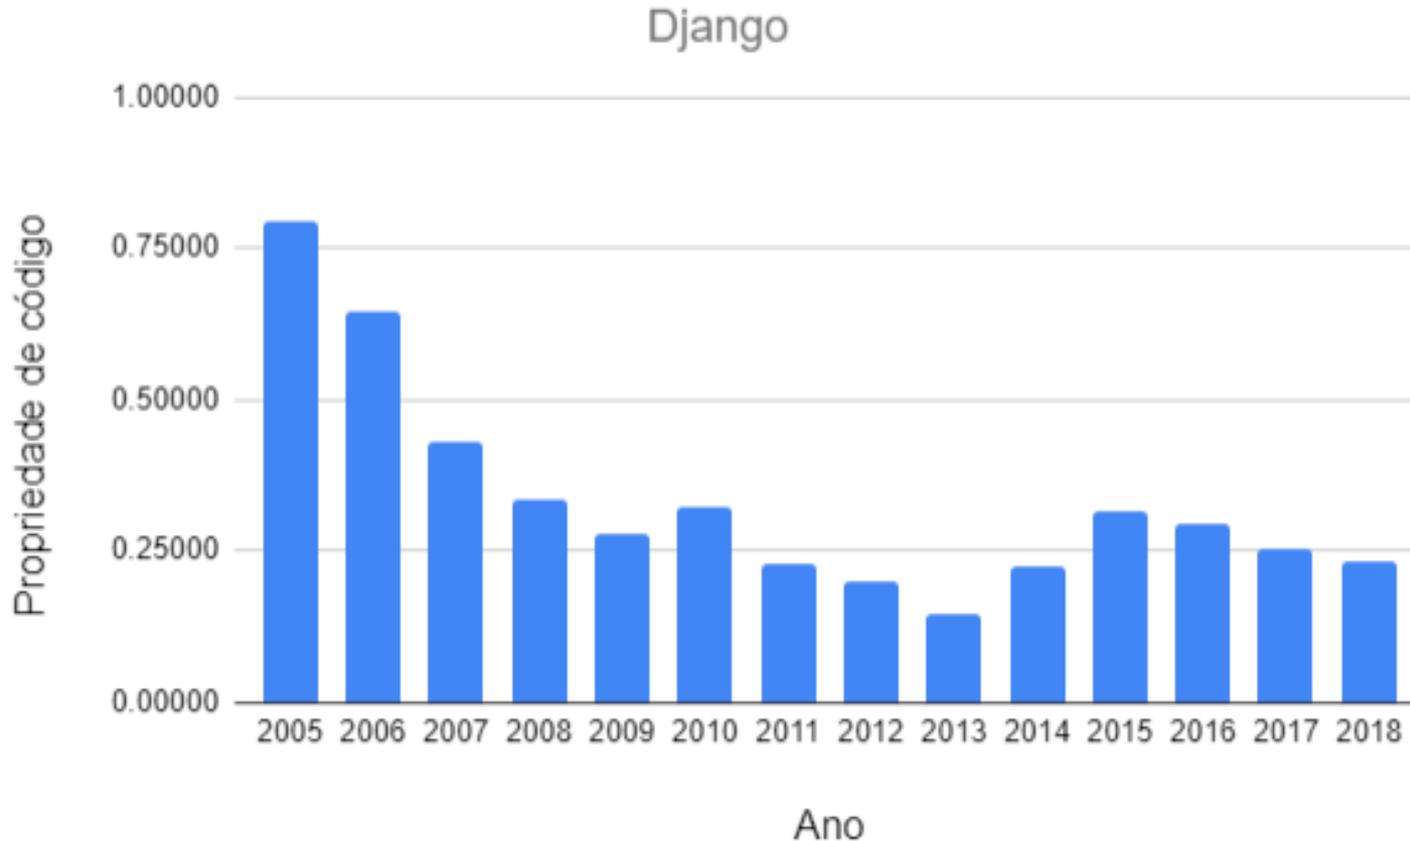
$$\max(\{ own_{p,d} \mid d \in D \})$$

Propriedade de Código no Ciclo Evolutivo do Software

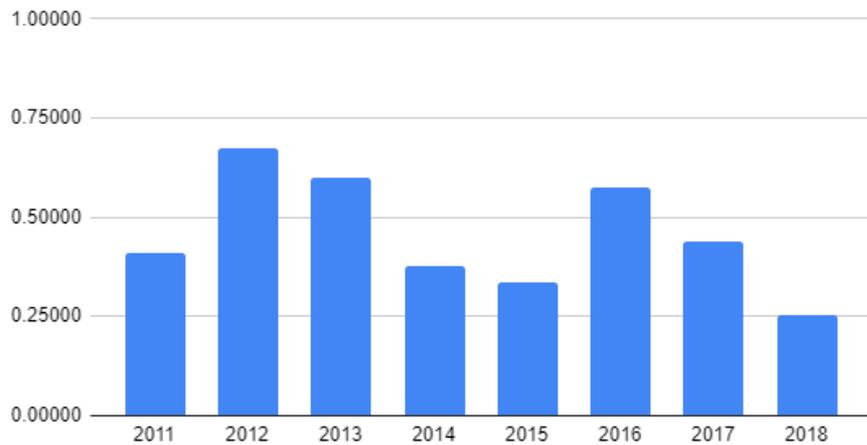
- A métrica foi calculada para cada período de tempo T
- Considerando que:
 - $\omega(p,t)$ é a soma de todas contribuições realizadas no projeto p em uma janela de tempo t
 - $\omega(d,t)$ é a soma de todas contribuições realizadas pelo desenvolvedor d em uma janela de tempo t

$$own_{t,d} = \frac{\omega(d,t)}{\omega(p,t)} \quad \max(\{ own_{t,d} \mid d \in D \})$$

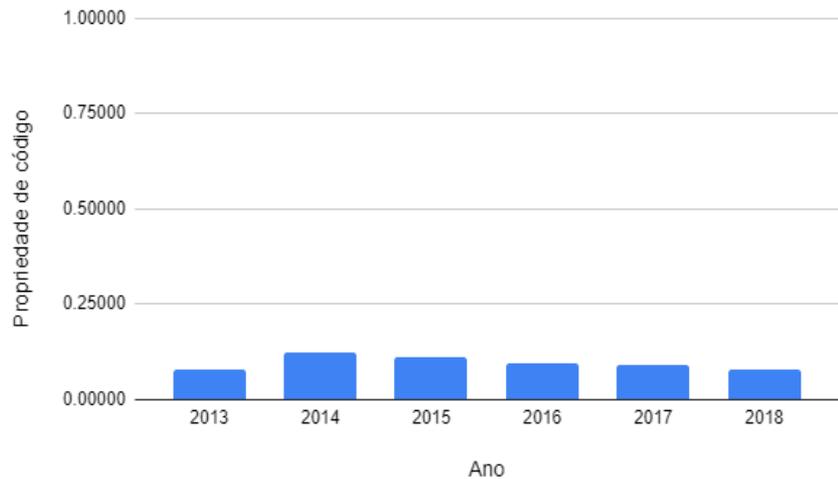
Propriedade de Código no Ciclo Evolutivo do Software



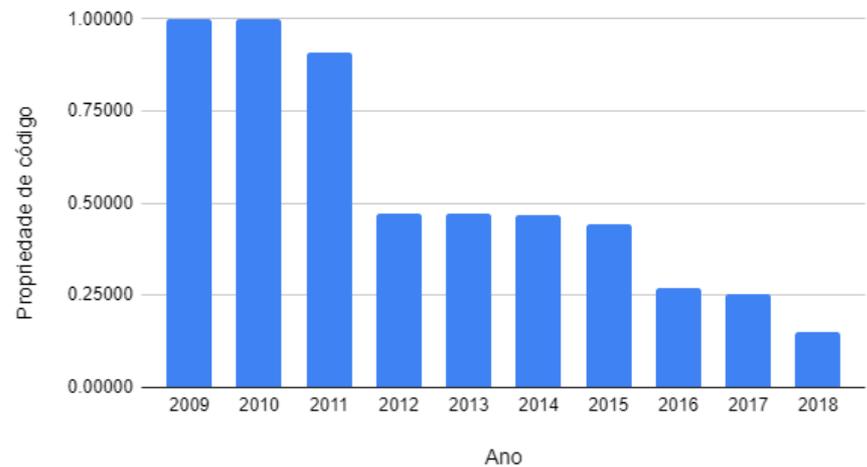
Bootstrap



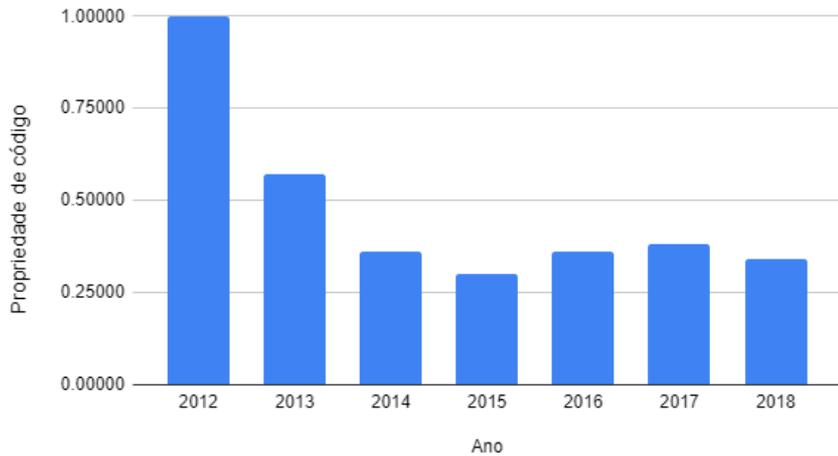
Elasticsearch



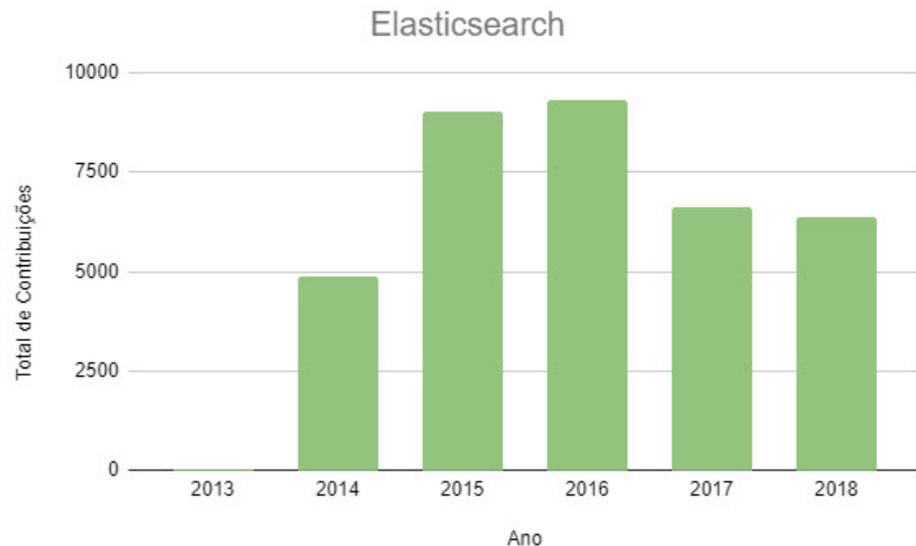
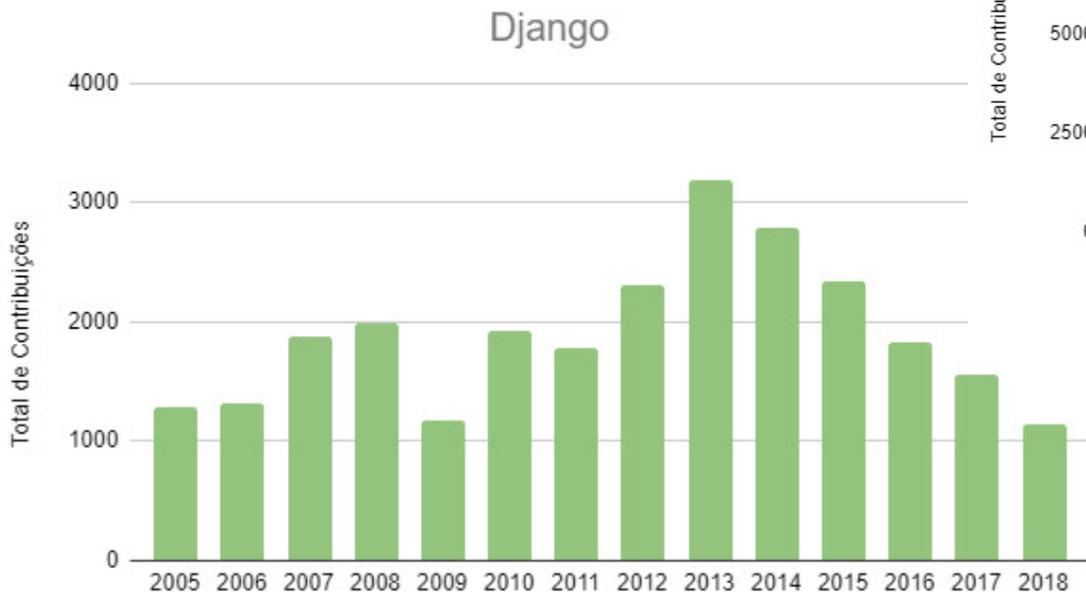
Panda



Spring Boot



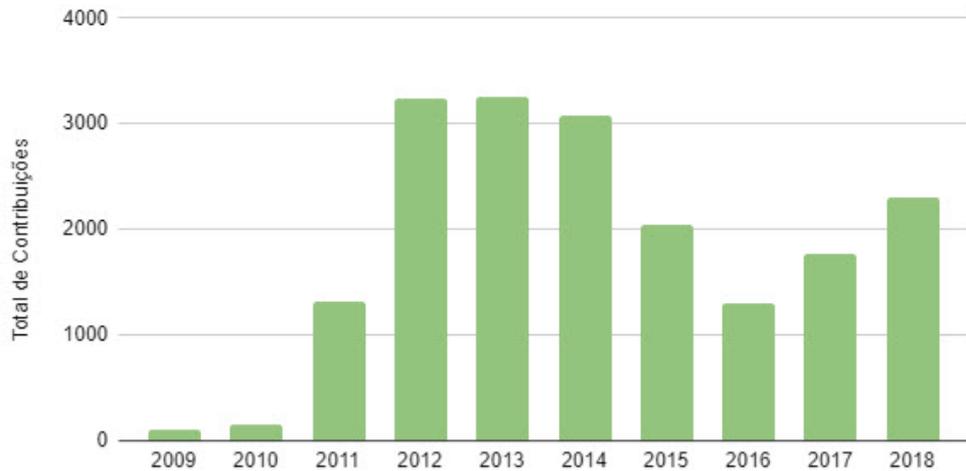
Frequência de Contribuição no Ciclo de Vida do Software



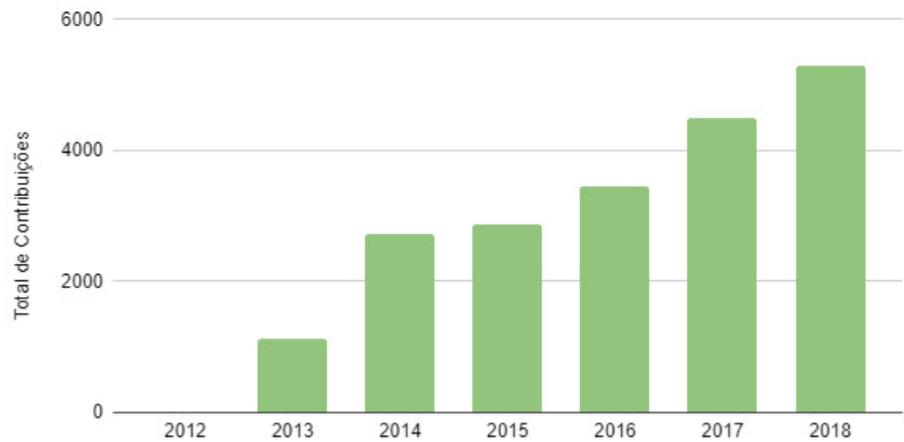
Bootstrap



Panda



Spring Boot



Correlação entre a propriedade de código e o total de contribuições

| Projeto | Correlação de <i>Spearman</i> | Classificação |
|---------------|-------------------------------|-----------------------------|
| Bootstrap | 0,5 | correlação direta moderada |
| Django | -0,376 | correlação inversa fraca |
| Elasticsearch | 0,257 | correlação direta fraca |
| Pandas | -0,339 | correlação inversa fraca |
| Spring Boot | -0,571 | correlação inversa moderada |

- Para os projetos analisados **não existe correlação**, entre o valor da propriedade de código e a variação da quantidade de contribuições efetuadas no repositório

Correlação entre as contribuições do proprietário e o total de contribuições do período

| Projeto | Correlação de <i>Spearman</i> | Classificação |
|---------------|-------------------------------|-------------------------------|
| Bootstrap | 0,952 | correlação direta muito forte |
| Django | 0,2 | correlação direta fraca |
| Elasticsearch | 0,841 | correlação direta forte |
| Pandas | 0,672 | correlação direta moderada |
| Spring Boot | 0,964 | correlação direta muito forte |

- Há uma **correlação direta** entre as contribuições do proprietário do período e o total de contribuições do período nos projetos

Respostas das Questões de Pesquisa QP1, QP2 e QP3



QP1: O conhecimento do software se difunde ao longo do ciclo de vida?

- Conhecimento é restrito a uma pequena parcela de autores, nomeados *heroes*
 - 80% dos contribuidores realizam até 2 *commits*
- **Tendência de disseminação do conhecimento** à medida que o software evolui
 - Ao analisar a evolução do valor da métrica de propriedade de código
 - Métrica tem valores menores nos últimos períodos analisados

QP2: Os desenvolvedores considerados *heroes* nas primeiras versões permanecem *heroes* durante a evolução do projeto?

- Os *heroes* iniciais **não** estão presentes dentre os *heroes* finais
 - O autor que mais contribuiu no primeiro período apresentou nenhuma ou uma quantidade pequena de contribuições no último período analisado
 - Comportamento **unânime** nos cinco projetos
- Os *heroes* **não** ocupam essa posição de modo **simultâneo**
 - Em cada período T, concentra-se em um ou dois deles
- Diminuição das contribuições dos *heroes* ocorre de modo **gradual**
- Evolução de um autor, considerado periférico, até tornar-se *hero* também é gradual

QP3: A concentração do conhecimento é impactada pela quantidade total de contribuições do projeto?

- Os resultados indicam que **não** se pode inferir nenhuma relação, direta ou inversa, entre o valor da métrica de propriedade de código e a variação no número de contribuições totais do projeto
- Apenas a avaliação da variação da quantidade de contribuições **não é o suficiente** para compreender a variação no valor da métrica de propriedade de código no ciclo evolutivo

Distribuição do Conhecimento de Software Análise Qualitativa



Survey



PERFIL DO DESENVOLVEDOR



DISSEMINAÇÃO DO CONHECIMENTO

Público Alvo

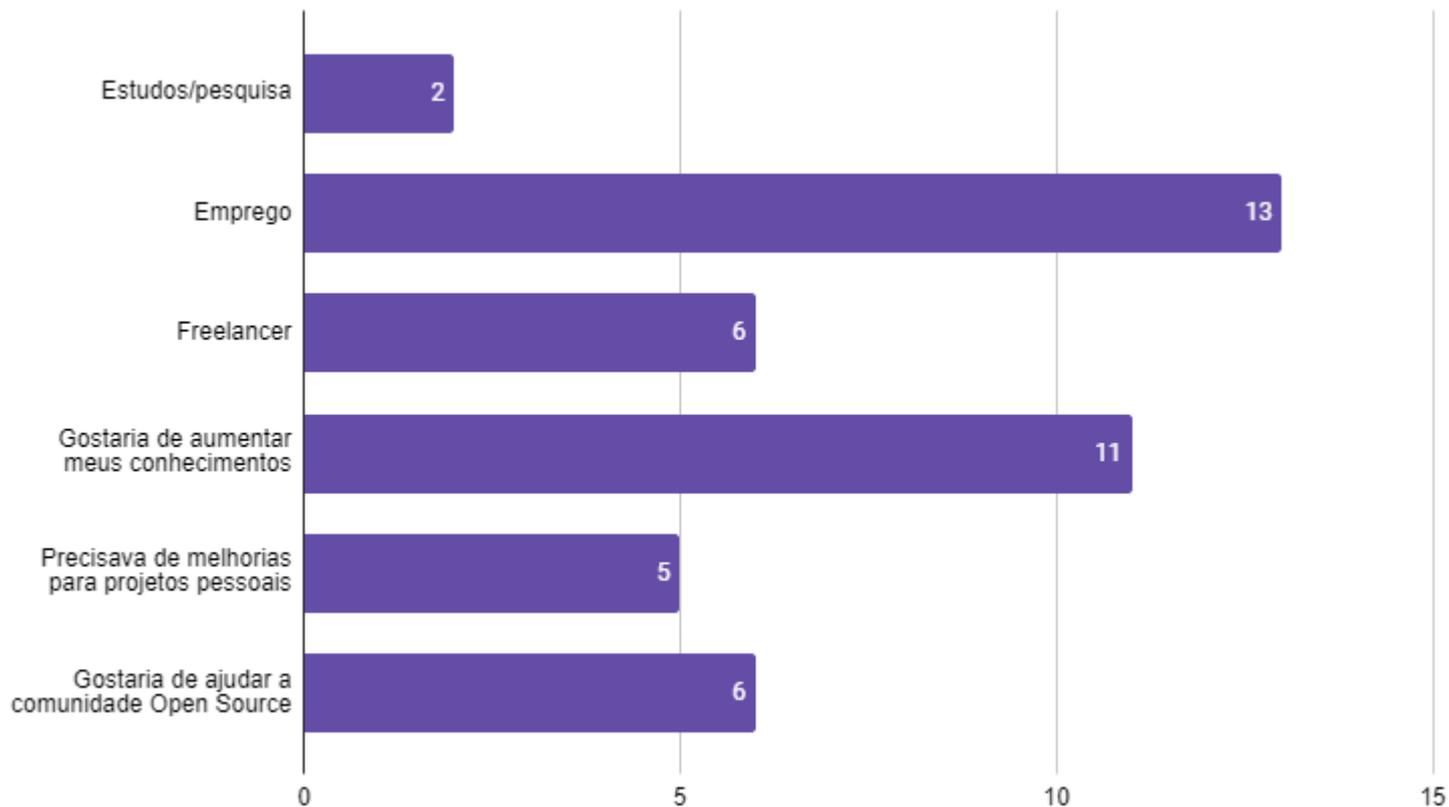
| Categoria | Total de autores selecionados (%) | Total de e-mails enviados | Total de respostas |
|-------------------|--|----------------------------------|---------------------------|
| Hero | 100% | 21 | 1 |
| Médio | 100% | 44 | 5 |
| Periférico | 5% | 347 | 41 |

Total de 47 respostas (11% do total enviado)

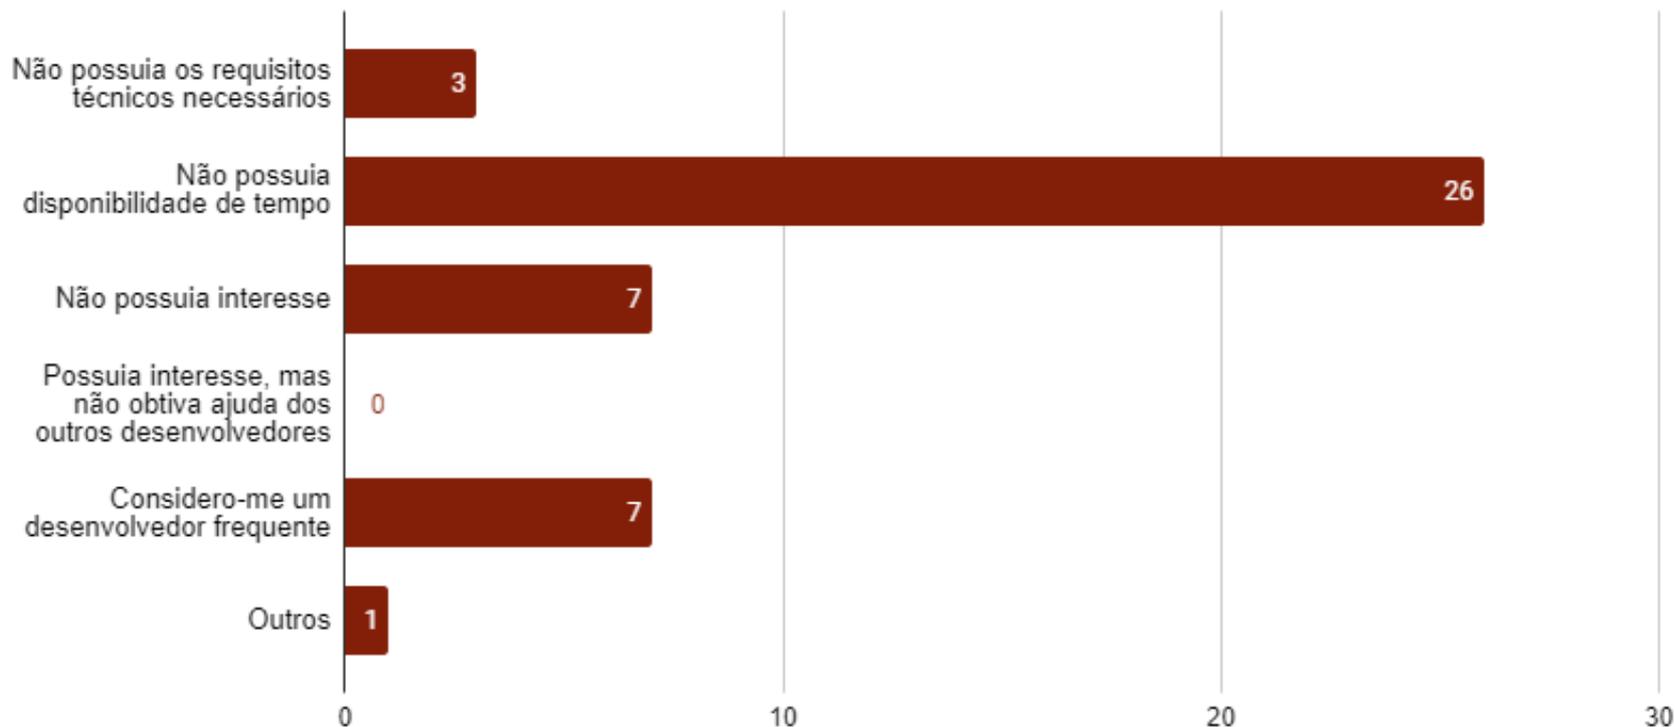
Resultados do Survey



Autores periféricos - Motivação principal para contribuições no projeto

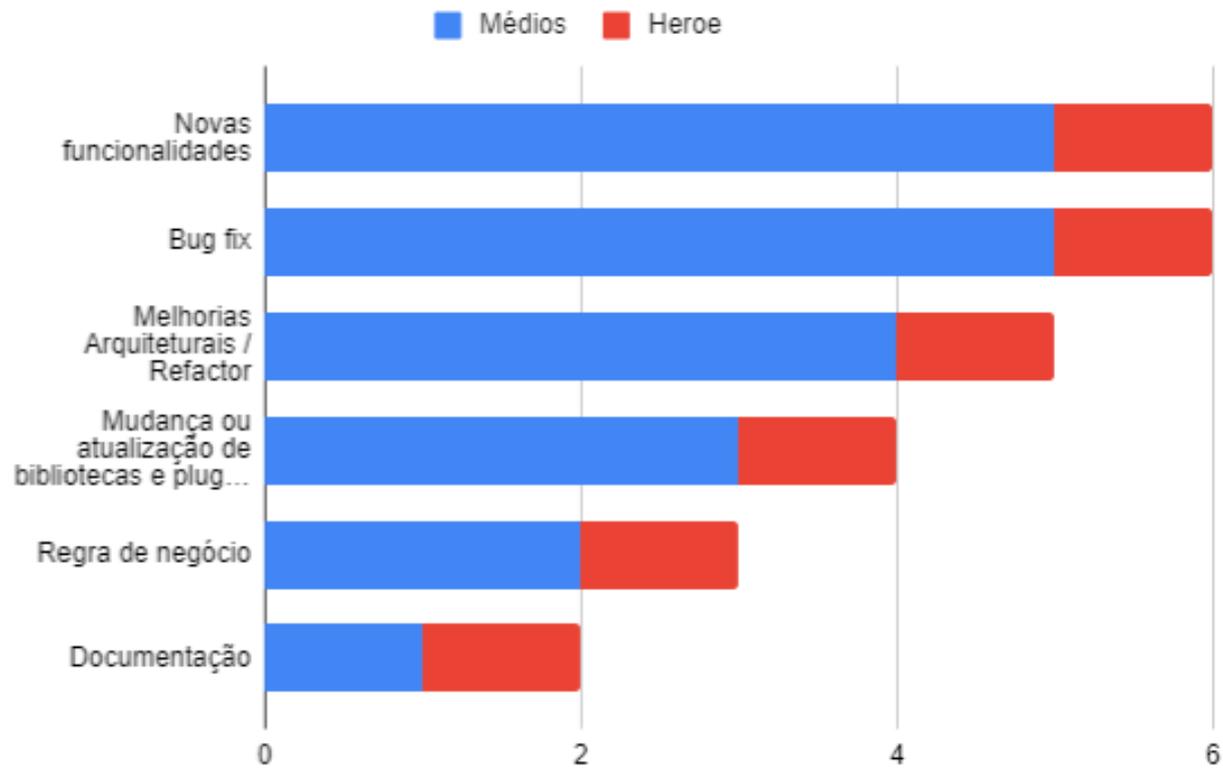


Autores periféricos - Razões para não ter se tornado um autor frequente no projeto



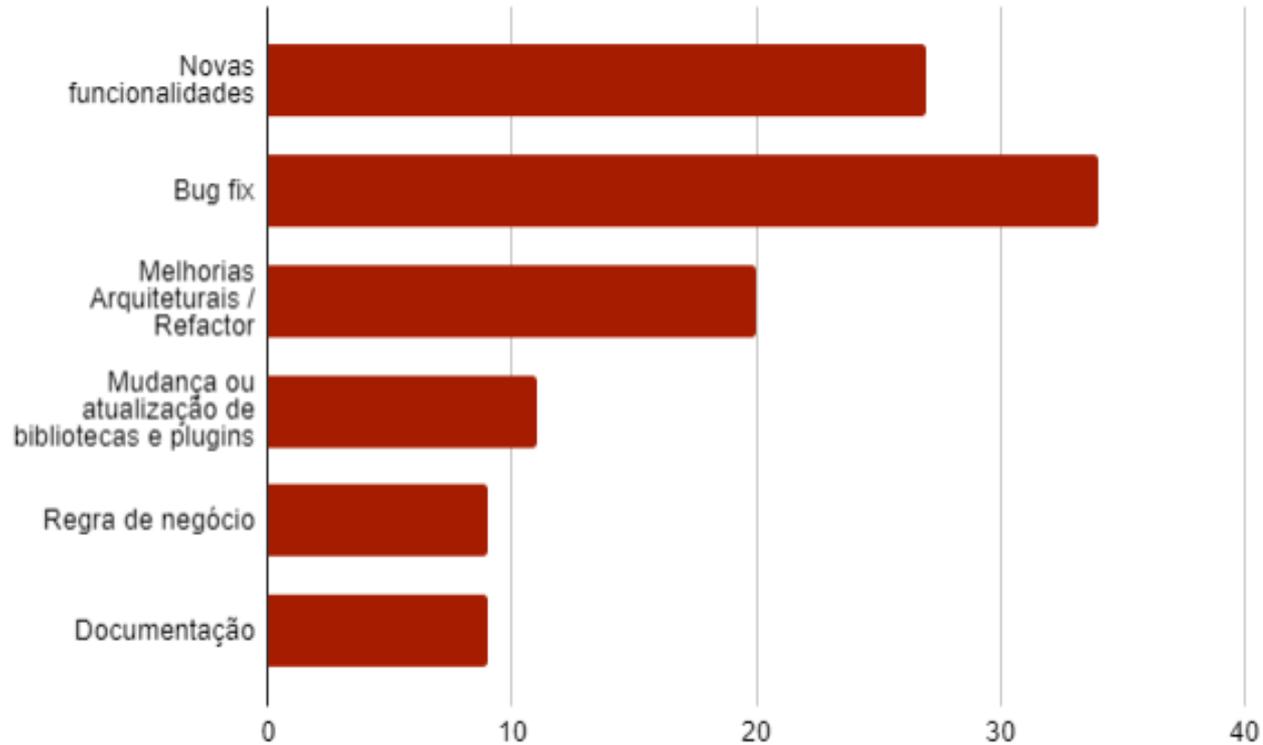
Autores médios e heroes - Tipos de contribuições efetuadas

Disseminação do conhecimento



Autores periféricos - Tipos de contribuições efetuadas

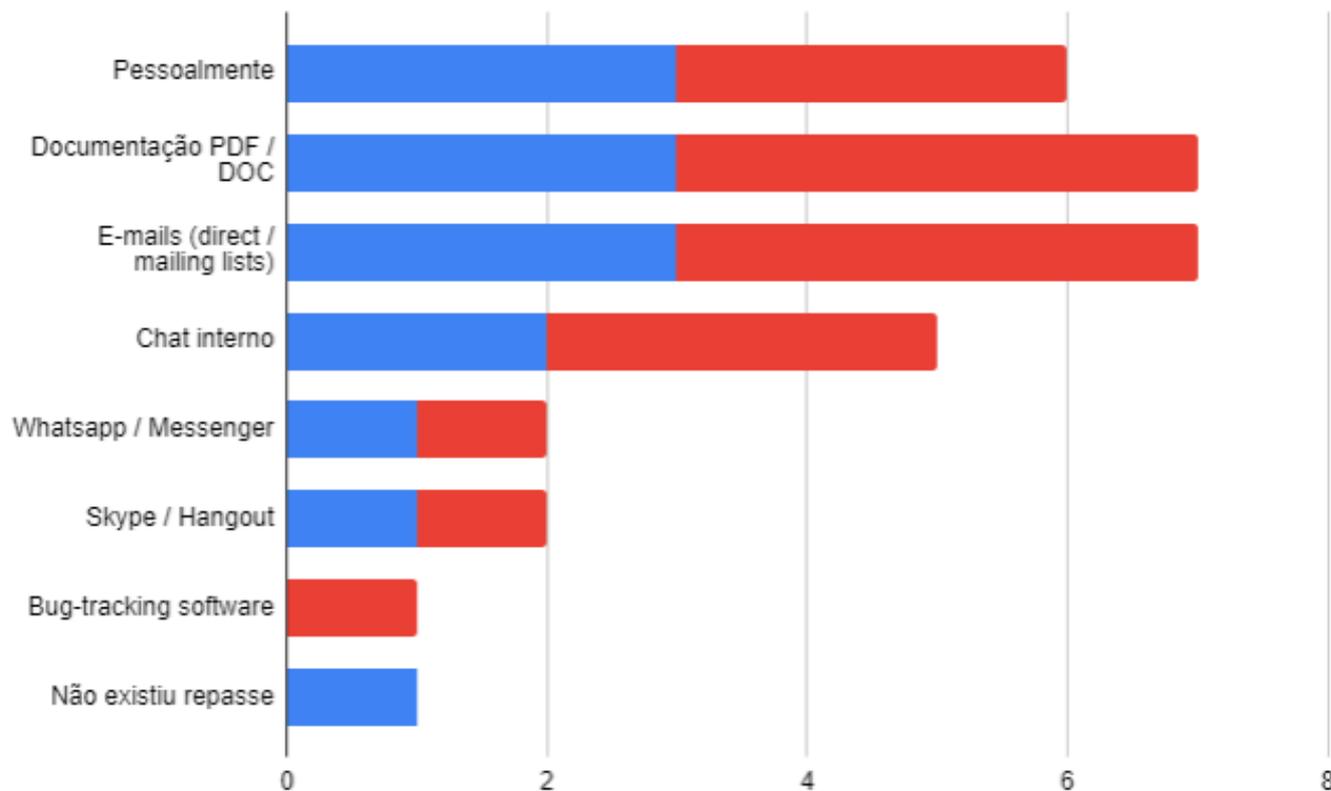
Disseminação do conhecimento



Autores periféricos - Recebeu ajuda de outros colaboradores do projeto?

1. Não recebi ajuda e não era necessário **25%**
2. Não recebi ajuda, mas era necessário **0%**
3. Recebi ajuda **75%**
 - Por meio do envio de **sugestões**, conselhos e **feedbacks** por parte dos autores mais experientes
 - **Code review** e co-contribuição
 - **Conversas** pelo *chat*, e-mail e *issue tracker*
 - Reuniões e *meetups*
 - Orientação sobre padrões de codificação

Autores médios e heroes - Transferência de conhecimento do software



Respostas das Questões de Pesquisa QP4 e QP5



QP4: Como se dá a atuação dos desenvolvedores periféricos nos projetos?

- Falta de disponibilidade de tempo
 - Principal razão para não aumentar a quantidade de contribuições
- Correções de *bugs*, acréscimo de novas funcionalidades, melhorias arquiteturais e correção na documentação do projeto
- Principais motivações
 - Emprego, desejo de aumentar conhecimentos técnicos ou contribuir com a comunidade *open source*, *freelancer* e melhorias em projetos pessoais
- Dificuldade de comunicação não é um fator preponderante que os levou a contribuir pouco

QP5: Como ocorre a disseminação de conhecimento do software entre os autores?

- Por meio da contribuição no código
 - Pelo desenvolvimento de novas funcionalidades, correção de *bugs* e melhorias arquiteturais
- Compartilhamento de conhecimento extra-código nas duas vias
- Troca de informações
 - Documentações de projeto
 - E-mails, *chats*, pessoalmente
 - *Bug-tracking*
- Nenhum autor relatou dificuldade de comunicação ou obstáculos na aquisição dos conhecimentos necessários
 - Facilita entrada de novos colaboradores

Conclusão



Conclusão

- Estudo de caso com cinco grandes projetos *open source*
 - Compreender como ocorre a evolução da distribuição de conhecimento entre os desenvolvedores durante o ciclo de vida do software
- Coleta de dados do GitHub
 - Disponibilização de dados e *scripts* para replicação e extensão do trabalho
- Estudo da atuação dos *heroes* no ciclo evolutivo do software
 - Existe uma alternância entre os heroes
 - *Series of generations*" [Robles et al., 2009]
 - Investir em ações de retenção
 - Importante para **evolução** e sustentabilidade do projeto

Conclusão

- Métrica de propriedade de código no decorrer da evolução de projetos *open source*
 - Propriedade de código do projeto tende a diminuir
- Resultados sugerem que o conhecimento torna-se mais distribuído entre os desenvolvedores no decorrer de seu processo evolutivo
 - Não há relação entre a variação do total de contribuições do projeto e a métrica de propriedade de código

Conclusão

- O desejo de aumentar os conhecimentos técnicos e contribuir com a comunidade *open source* são fortes motivos que levam periféricos a contribuir nos projetos
- Falta de disponibilidade de tempo e interesse são fatores que atrapalham a continuidade das contribuições
- Importância da **distribuição de conhecimento**
 - Cenários extra-código
 - Compartilhamento de informações é vital para subsistência de todo projeto

Trabalhos Futuros



- Replicar estudo utilizando *dataset* maior e comparar com diferentes métricas e granularidades
- Construção de algoritmos de desambiguação com maior valor de precisão
- Construir ferramenta que permite a coleta e caracterização dos dados de forma automatizada

Evolução da Distribuição de Conhecimento de Software em Projetos *Open Source*

Talita Santana Orfanó

Orientadoras: Mariza A. da Silva Bigonha e Kecia Aline M. Ferreira

Obrigada!



ANEXOS

Trabalhos Relacionados

**Fatores Humanos
e Organizacionais**



**Autoria e Propriedade
de Código**



**Heroes
vs
Periféricos**



Desambiguação de Autores

- **Por login**
 - O dados de login retornados pela API corresponde ao ***committer***, ao invés do **autor**
 - Em muitos casos, pode coincidir de serem a mesma pessoa
 - Contudo, assumir isso apresenta sérios riscos aos resultados da coleta e a respectiva análise
 - Desambiguação por meio de login não é adequada para o nosso estudo

```
"sha": "55ffcf8e7b414a39e2dfc9c9eb4c5d3fa548e78e",
"node_id": "MDY6Q29tbWl0NDE2NDQ4MjJo1NwZmY2Y4ZTd0NDE0YTM5ZTJkZmM5YzllYjRjNWQzZmE
"commit": {
  "author": {
    "name": "Raúl Cumplido",
    "email": "raulcd@tid.es",
    "date": "2012-06-07T11:46:06Z"
  },
  "committer": {
    "name": "Tim Graham",
    "email": "timograham@gmail.com",
    "date": "2012-06-30T21:16:40Z"
  },
  "url": "https://api.github.com/repos/django/django/commits/55ttctf8e7b414a39e2d1
  "html_url": "https://github.com/django/django/commit/55ffcf8e7b414a39e2dfc9c9e1
  "comments_url": "https://api.github.com/repos/django/django/commits/55ffcf8e7b4
  "author": null,
  "committer": {
    "login": "timgraham",
    "id": 411869,
    "node_id": "MDQ6VXNlcjQxMTg2OQ=="
```

Desambiguação de Autores

- **Por nome / e-mail - Uso de heurísticas**
 - Estudo e comparação de cinco heurísticas de desambiguação de autores em projetos *open source*
 - Bird, Canfora, Simple, Robles e Goeminne
 - Resultados
 - Alto coeficiente de revocação (*recall*) - 100%
 - Baixa precisão em projeto de grande porte - ~30%
 - Mesmo sob essas circunstâncias, optou-se por avaliar os resultados geradas por uma dessas heurísticas: Bird

```

1 início
2   ambiguidade ← falso;
3   t ← 0,93;
4   Normalização dos dados (autor1, autor2);
5   se Similaridade do nome completo(autor1.nome, autor2.nome) ≥ t OU
6     (Similaridade primeiro nome(autor1.nome, autor2.nome) ≥ t E
7       Similaridade último nome(autor1.nome, autor2.nome) ≥ t ) OU
8     Similaridade entre os prefixos de email(autor1.email, autor2.email) ≥ t
9       OU
10    Prefixo contém primeiro e último nome(autor1.email, autor2.nome) OU
11    Prefixo contém primeiro e último nome(autor2.email, autor1.nome) OU
12    Prefixo contém primeiro nome e inicial do último nome(autor1.email,
13      autor2.nome) OU
14    Prefixo contém primeiro nome e inicial do último nome(autor2.email,
15      autor1.nome) então
16      | ambiguidade ← verdadeiro;
17    fim
18  retorna ambiguidade
19 fim

```

Desambiguação de Autores - Heurística Bird

- A heurística foi executada para os autores dos cinco projetos
- Os resultados foram avaliados manualmente
 - Existência de problemas consideráveis na identificação dos autores
 - Algoritmo e resultados estão disponíveis para consulta

Bootstrap:

- contact@helmutgranda.com, contact@weirdog.com e contact@dominicbarnes.us
- cesidio.dilanda@gmail.com, sidp@knights.ucf.edu e sid@sidroberts.co.uk

Django:

- bphillips (bphillips@cactusgroup.com) e Joshua Philips (jphillips@imap.cc)
- Thomas Orozco (thomas@orozco.fr) e Thomas Sorrel (thomas@pandeiro.fr)

Elasticsearch:

- ludo.helder@gmail.com e ludovic@xwiki.com
- Tim B (tim@uncontended.net) e Tim Venum (tim@adjective.org)

Panda:

- joejev@gmail.com e joe@quantopian.com
- John Freeman (jfreeman08@gmail.com) e Jesse Farnham (jfarnham20@gmail.com)

Spring boot:

- alexander.abramov.pub@gmail.com e alexander.constantin@gmail.com
- Jay Anderson (jaanderson@shutterfly.com) e Jayaram Pradhan (jayaramimca@gmail.com)

Propriedade de Código no Ciclo Evolutivo do Software

- Adaptando as notações desenvolvidas por Foucault et al. [2014] para o contexto do presente estudo, pode-se considerar que:
 - $\omega(p)$ é a soma de todas contribuições dos desenvolvedores realizadas em um projeto p
 - $\omega(d)$ é a soma de todas contribuições realizadas por um desenvolvedor d
 - $\omega(p, d)$ é a soma de todas contribuições realizadas por um desenvolvedor d em um projeto p

100M*

repositories worldwide

50M*

developers
worldwide

2.9M*

businesses &
organizations
worldwide

Autoria de Software e Propriedade de Código

Autoria de Software

O termo autoria de software é utilizado para referenciar o autor responsável por um trecho de código ou módulo

Propriedade de Código

O conceito de propriedade de código pode ser utilizado para distinguir dentre os autores do projeto aquele que possui uma maior responsabilidade, ou seja, aquele desenvolvedor que criou ou alterou a maior parte do código existente no módulo ou projeto analisado