

トピックモデリングに基づく開発者検索 手法の構築

オープンソース・ソフトウェア工学研究室

60190101

福井 克法

背景

- 効率的な開発には適切な人材配置が重要
- 開発者の全ての業務経験を把握することは困難



先行研究と問題点

- **先行研究**

- ファイル変更履歴に基づいた検索手法[1][2]

- **実際の開発組織で利用する上での問題点**

- 要件定義や基本・詳細設計にのみにしか関わっていない開発者を対象とできない

[1]Mockus, A. and Herbsleb, J. D.: Expertise Browser: A Quantitative Approach to Identifying Expertise, Proceedings of the 24th International Conference on Software Engineering, ICSE '02, pp. 503–512 (2002).

[2]Robbes, R. and Rothlisberger, D.: Using Developer Interaction Data to Compare Expertise Metrics, Proceedings of the 10th Working Conference on Mining Software Repositories, MSR '13, pp. 297–300 (2013).

目的とアプローチ

- 目的

- 全工程を対象として開発者を広く検索できる手法を構築

- アプローチ

1. メーリングリストアーカイブにトピック分析を適用
2. 結果に基づいて検索単語により開発者を検索


トピック分析

- トピック分析

- 文章に含まれる可能性あるのトピック（話題）を抽出する

- Latent Dirichlet Allocation(LDA)


- 1つの文書が複数のトピックからなることを仮定した言語モデル



- トピック分布, トピックごとの単語分布を求める

Latent Dirichlet Allocation

- 文書生成過程



LDAのグラフィカルモデル

θ : 文書におけるトピックの単語分布

ϕ : トピックにおける単語の多項分布

Z : 語 W に割り当てられたトピック

K : トピック数


M : 文書数

n : 単語数

α : トピック数 θ が従うディリクレ分布のハイパーパラメータ


β : 単語分布 ϕ が従うディレクリ分布のハイパーパラメータ

提案手法の概要




1.1. メーリングリストアーカイブへのLDAの適用

1. メーリングリストアーカイブ全体のトピックと単語分布の抽出



2. メーリングリストアーカイブへの各投稿のトピック分布の抽出



2. 検索語と各投稿の定量化

- 検索語と各投稿, 各開発者を定量的に評価する

1.DocumentScoreの算出 (検索語と投稿の関係)

$$\sum_{k=1}^5 \theta_{t_k, w_i} \times \phi_{t_k, d_j}$$

検索語の生起確率

投稿のトピック分布

2.AuthorScoreの算出 (検索語と開発者の関係)

$$\sum_{m=1}^{NumberOfMail} DocumentScore_{w_i, d_m}$$

θ_{t_k, w_i} : トピック t_k における検索語 w_i の生起確率

ϕ_{t_k, d_j} : 投稿 d_j におけるトピック t_k のトピック分布の比率

3. 開発者の順位づけ

- 検索語と関係のあると考えられる開発者を順位付ける

DocumentScore

AuthorScore

検索語 →

	1.04		2.00
	2.00		1.12
	1.00		1.30
	0.22		1.00
	1.32		1.30

→

1.		   	2.00 1.30 1.04 1.00	5.34
2.		 	2.00 1.12	3.12
3.		  	1.00 0.22 1.00	2.22
4.			1.32	1.32
			⋮	

検索語と投稿の関係

検索語と開発者の関係

評価実験

- 目的：有用性の評価

- キーワードに関係する開発者を正しく検索できていることを確認する

- 実験方法

1. 正解集合を作成するために複数プロジェクトのメーリングリストを合成
2. 各プロジェクトに関する語を用いて開発者を検索
3. 開発者の正答率で評価を行う

データセット

- Hadoopのサブプロジェクト
 - 比較的内容が近いと考えられるため


プロジェクト	期間	件数	開発者数
Apache Hive	2008/11/11~2010/10/07	1,881	28
Apache Pig	2007/10/31~2010/09/28	1,662	44
Apache Zookeeper	2007/10/31~2010/09/28	1,506	23
Apache Chukuwa	2009/03/10~2013/10/08	877	25
合計		4,209	118

実験手順

1. 各OSSプロジェクトから検索語を抽出
 - ▶ 特徴語(tf-idf値を利用)と頻出語(df値を利用)
2. LDAのトピック数を100, 500, 1000に設定し手法を適用
3. 手法により出力された上位10名の開発者の正答率を算出

実験の概要

- Zookeeperの開発者を検索する例



抽出した特徴語

- クラス名や変数名が抽出できている

	Apache Hive	Apache Pig	Apache Zookeeper	Apache Chukuwa
1	hiveopensource	physicallay	nioservercnxn	adapter
2	srcpart	pig	zookeep	chukwa
3	metaexcept	mapreducelay	nioservercxn	hicc
4	jobconf	cocoon	todd	demux
5	thrift	gld	clientcnxn	collector
6	srcbucket	inactiveaccount	socket	seqfilewrit
7	protect	piggybank	peer	agent
8	numreducetask	eq	antlib	row
9	processnam	acct	hunt	depart
10	libjar	foreach	elect	scienc

抽出した頻出語

- プロジェクト名やソフトウェア開発で頻繁に利用される語が抽出できている

	Apache Hive	Apache Pig	Apache Zookeeper	Apache Chukuwa
1	hiveopensource	pig	zookeep	chukuwa
2	hive	physicallay	hunt	adaptor
3	srcpart	mapreducelay	nioservercnxn	hicc
4	thrift	schema	clientcnxn	demux
5	metaexcept	foreach	todd	collector
6	jobconf	gate	elect	scienc
7	srcbucket	cocoon	socket	depart
8	protect	piggybank	nioservercxn	jiaqi
9	numreducetask	gld	lock	agent
10	metastor	javacc	peer	seqfilewrit

特徴語を用いた結果

- 各検索語で検索を行った際の上位10名での正答率平均

プロジェクト	トピック数		
	100	500	1000
Apache Hive	81%	61%	62%
Apache Pig	91%	100%	99%
Apache Zookeeper	61%	70%	73%
Apache Chukuwa	71%	67%	78%

頻出語を用いた結果

- 各検索語で検索を行った際の上位10名での正答率平均

プロジェクト	トピック数		
	100	500	1000
Apache Hive	78%	65%	66%
Apache Pig	86%	99%	91%
Apache Zookeeper	66%	75%	75%
Apache Chukuwa	71%	69%	82%

正答率の低い検索語

正答率が特に低かった検索語

thrift	libjar	javacc	socket
antlib	row	scienc	hicc
peer	numreducetask	srcbucket	seqfilewrit
jobconf			

- ソフトウェア開発において頻繁に利用される用語
- 複数のプロジェクトで使われる語が多い
 - thrift : Apache Thrift
 - javacc : Java Compiler Compiler . . .

まとめと今後の課題

- **まとめ**

- MLアーカイブにトピック分析を適用し検索手法を提案
- 合成データを用いて評価実験の実施
 - ▶ 正答率は6割～10割

- **今後の課題**

- 評価実験に合成データを用いている
- 検索語の抽出の再検討

大学院での予定

- 別アルゴリズムとの比較
 - Word2vecなど
 - ▶ Word2Vecにより，比較的意味の近い語が取得できることを確認
(Apache httpdメーリングリストの語を学習)

入力語	database	network
	rdbm	packet
類似度の 高い語	mysql	gigabit
	access	zero-copi
	postgr	latenc
	queri	ethernet
	informix	sniffer
	postgresql	sendfil
	postgres95	congest
	metabas	socket
	mysql	traffic