

Uma Análise Preliminar da Hiperespecialização no Contexto de *Crowdsourcing* na Plataforma Topcoder

Anderson Bergamini de Neira¹, Igor Scaliante Wiese², Igor Steinmacher^{1,2}

¹Departamento de Informática – Universidade Estadual de Maringá

²Departamento de Computação – Universidade Tecnológica Federal do Paraná

andersonneira@gmail.com, {igor, igorfs}@utfpr.edu.br

Resumo. *Diversas empresas de todo o mundo utilizam plataformas de crowdsourcing para, por exemplo, completar pequenas tarefas, receber ideias de produtos ou campanhas publicitárias, entre outros. Recentemente, crowdsourcing passou também a ser utilizado como uma opção de desenvolvimento de software, seja para executar testes, corrigir pequenos defeitos ou para executar pequenas tarefas de codificação. Um dos pilares que garantem o funcionamento do modelo de negócio do crowdsourcing são os participantes das plataformas, pois eles são os responsáveis pela execução das tarefas solicitadas. Entendendo isso, torna-se necessário saber como os participantes se comportam a fim de atraí-los para e retê-los nas plataformas. Assim, o objetivo deste trabalho é conduzir um estudo exploratório para entender um perfil de contribuição específico: os hiperespecialistas. Para isso, analisou-se o tipo de desafio que 664 desenvolvedores da plataforma Topcoder participaram durante os primeiros 18 meses de sua participação. Conduziu-se uma análise quantitativa, e, como resultado, observou-se que, em geral, os usuários que não deixam de participar possuem traços comportamentais que indicam a hiperespecialização, pois estes participam majoritariamente dos mesmos tipos de desafio. Um achado interessante (e preocupante) foi a alta taxa de desistência na plataforma: 66% dos participantes interromperam sua participação durante o período avaliado.*

Palavras-chave: crowdsourcing, topcoder, hiperespecialização.

1. Introdução

Um novo conceito para o desenvolvimento de software está se consolidando na indústria e atraindo a atenção de empresas [Mao et al. 2016], desenvolvedores [Xie et al. 2014, Karim et al. 2016] e pesquisadores. O *crowdsourcing* para o desenvolvimento de software se beneficia do *pool* de desenvolvedores globalmente distribuídos, para realizar tarefas que são propostas por empresas do mundo inteiro [Mao et al. 2015]. O *crowdsourcing* proporciona aos participantes engajados uma forma de ganhar dinheiro, notoriedade e até mesmo oportunidades profissionais [Saremi and Yang 2015]. As empresas, por sua vez, têm no *crowdsourcing* uma forma econômica e confiável de desenvolver software, contando com a “sabedoria das multidões” [Surowiecki 2005] para completar as tarefas.

Para que seja possível manter um ambiente próspero e vantajoso para todos os envolvidos com *crowdsourcing* faz-se necessário um alto nível de interação entre **empresas** (que precisam de artefatos de software), **desenvolvedores** (que podem criar esses artefatos), **tarefas** e **plataformas** (que gerenciam a

necessidades)[LaToza and van der Hoek 2016]. Para a sustentabilidade das plataformas, é necessário, então, garantir a entrada e retenção de novos desenvolvedores. Devido à importância dos desenvolvedores para o sucesso do *crowdsourcing*, autores abordam algumas características a respeito do perfil de contribuição dos usuários. Apesar de estudos encontrados na literatura terem analisado algumas características acerca dos diferentes modos de contribuição [Saremi and Yang 2015, Mao et al. 2016] e mesmo com o número de trabalhos relacionados a *crowdsourcing* para desenvolvimento software ter aumentado nos últimos anos [Ambreen and Ikram 2016], muito ainda se desconhece sobre o perfil de contribuição e o comportamento dos desenvolvedores que atuam nesse tipo de ambiente.

Em 2011, Malone et al. previa que entrávamos na era da hiperespecialização. Para os autores, uma das características dos participantes de plataformas de *crowdsourcing* seria a hiperespecialização, ou o profundo conhecimento de alguns assuntos específicos, o que segue em direção contrária aos atuais desenvolvedores *full stack*. Desenvolvedores com esse perfil beneficiam o crescimento do *crowdsourcing*, pois tornam real a possibilidade das empresas contarem com um *pool* global de especialistas a um valor reduzido, já que nem sempre é possível encontrar profissionais com habilidades específicas na região ou o alto custo pode inviabilizar a contratação dos mesmos.

Neste artigo é apresentado um estudo preliminar analisando o fenômeno da hiperespecialização dos desenvolvedores em ambientes de desenvolvimento de software baseados em *crowdsourcing*. A análise foi realizada examinando a classificação dos desafios executado por 664 usuários da plataforma Topcoder durante os primeiros 18 meses de cada um dos usuários. A plataforma Topcoder foi escolhida devido ao fato desta ser uma das maiores plataformas de desenvolvimento de sistemas baseado no *crowdsourcing* do mundo, contando com mais de um milhão de participantes cadastrados¹, tendo recebido mais de 22 mil tarefas e distribuído mais de oitenta milhões de dólares em recompensa desde sua fundação². Empresas com reputação internacional utilizam os serviços da plataforma Topcoder, por exemplo, NASA, IBM, eBay e Honeywell.

Os resultados preliminares indicam que aproximadamente 94% dos usuários que contribuíram durante todo o período analisado, mantêm-se contribuindo em desafios do mesmo tipo, indicando a possível existência da hiperespecialização citada por Malone et al. (2011). Outro importante resultado foi a grande taxa de desistência encontrada: cerca de 66% dos participantes que participam de ao menos um desafio na plataforma acabam cessando sua colaboração.

2. Trabalhos relacionados

Hosseine et al. (2014) defende a existência de quatro pilares que devem ser considerados para a prosperidade do *crowdsourcing*: a **empresa**; a **plataforma**; o **trabalhadores**; e as **tarefas**. Apesar da importância dos trabalhadores, muitos aspectos relacionados a interação e comportamento dos usuários nas plataformas não são entendidos.

Existem alguns trabalhos que se preocupam em analisar traços do comportamento de desenvolvedores em plataformas de *crowdsourcing*. Por exemplo, no trabalho de Gadiraju (2015) foram sugeridas classificações para usuários cujo o comportamento reflete ações contrárias às regras ou a usuários que não conseguem boas contribuições na plata-

¹<https://www.topcoder.com/community/members/>

²<https://www.topcoder.com/marketplace/the-community/>

forma. Gray et al. (2016) citam a existência de casos em que os próprios trabalhadores se ajudam, seja na motivação para continuar contribuindo com a plataforma.

Também existem trabalhos que retratam traços do perfil de contribuição dos participantes nas plataformas de *crowdsourcing* focadas no desenvolvimento de software. Saremi e Yang (2015) citam que membros mais experientes da plataforma Topcoder são propensos a buscar tarefas de empresas com fama internacional ou ainda com altas recompensas. Eles ressaltam pessoas mais experientes produzem mais, proporcionando chances de mais vitórias em suas disputas. Mao et al. (2016) relatam que os membros mais qualificados da plataforma Topcoder registram-se logo que a tarefa é disponibilizada, fato esse que acaba por inibir o cadastro de outros competidores de alto nível.

Assim como os trabalhos anteriormente citados remetem a características de usuários da plataforma, este também visa identificar uma característica dos usuários de *crowdsourcing*, a hiperespecialização. Tomando a definição de Malone et al. (2011), este trabalho tem por objetivo examinar de modo preliminar um dos possíveis modos de manifestação da hiperespecialização. De posse dessas informações é possível adequar as tarefas com o intuito de aumentar a qualidade das contribuições, consequentemente, obter melhores artefatos de software. O fato de conhecer, mesmo que em partes, as ações dos usuários auxilia as empresas na decisão de adotar o *crowdsourcing*.

3. Método

A Figura 1 apresenta o método proposto para a condução do estudo da verificação da hiperespecialização na plataforma Topcoder. Por meio dela é apresentado uma sequência de quatro passos: (i) coletar dados; (ii) amostrar participantes; (iii) definir especialidades; (iv) analisar a migração.

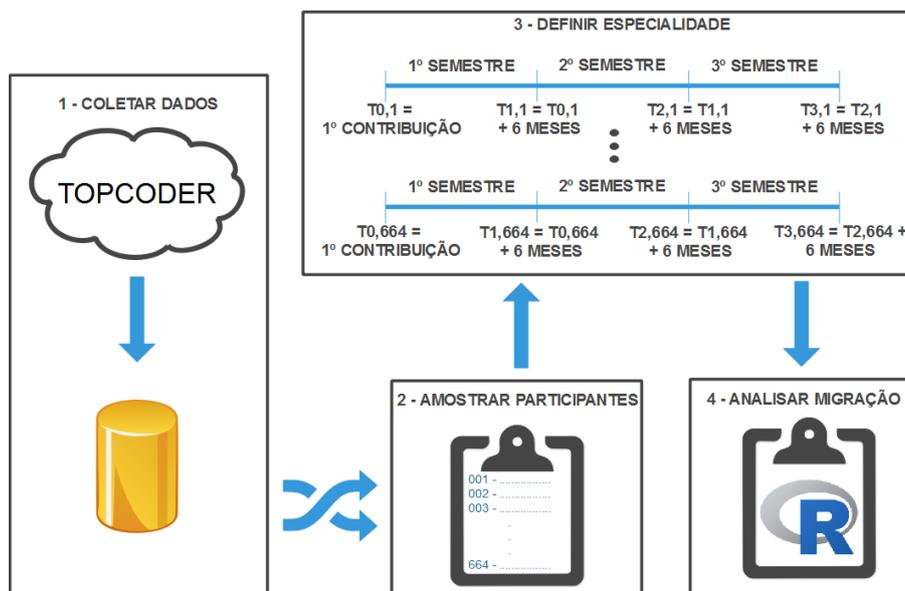


Figura 1. Método para a condução da fase de verificação da hiperespecialização

O passo 1 consistiu na coleta dos dados, que foi realizada por meio da *Application Programming Interface* (API) sem proteção que era oferecida pela plataforma Topcoder. Por meio do acesso a esses dados foi possível obter informações de cerca de 350 mil

usuários da plataforma. Os dados coletados referem-se à participação dos usuários nos desafios; metas atingidas na plataforma; tecnologias que os usuários dizem dominar; e informações pessoais, como país de origem e data do cadastro na plataforma. Neste trabalho apenas as participações nos desafios foram utilizadas.

No passo 2 a população amostral foi definida. Restringiu-se a amostra de acordo com os seguintes critérios: (i) os usuários deviam ter participado de, no mínimo, um desafio; e (ii) esse desafio deve datar de no mínimo 18 meses antes do início da coleta dos dados, uma vez que este foi o período de tempo que analisamos de cada usuário. Dentre os usuários que atendiam às restrições, foram amostrados 664 usuários de maneira aleatória. O tamanho da população amostral foi definida com um nível de confiança de 99% e um erro amostral de 5%, considerando a população atual da plataforma Topcoder (cerca de 1.120.000 usuários cadastrados).

No passo 3, contabilizou-se a quantidade de participações de cada usuário da amostra. Após essa contagem, analisou-se se a hiperespecialização pode ser encontrada de acordo com os tipos de tarefas escolhidas pelos usuários. Na plataforma Topcoder, as tarefas são classificadas em três grandes tipos: desenvolvimento; design; e ciência de dados. O intuito deste passo é conduzir uma análise temporal para cada membro da amostra, verificando a quantidade de desafios que cada usuário participou, de acordo com a classificação (desenvolvimento, design ou ciência de dados). Tal classificação serviu de base para a análise da existência (ou não) da hiperespecialização de acordo com o tempo. Para isso, a linha do tempo de cada participante foi definida individualmente, considerando a data de participação do primeiro desafio. Essa linha do tempo foi reduzida a 18 meses, iniciando pela data do primeiro desafio. Para análise de hiperespecialização, dividiu-se esse período em três partes, cada uma com seis meses (item 3 na Figura 1).

De posse da contagem das participações divididas em períodos de 6 meses, a determinou-se a especialidade dos participantes nos períodos estudados. Para isto, foi definido que um participante seria especialista em um determinado tópico se 75% ou mais dos desafios em que o desenvolvedor participou tem o mesmo valor para atributo sob análise (tipo de desafio). Caso os 75% não fossem alcançados, o participante foi classificado como "sem especialização". O participante foi classificado como "sem contribuição" caso não tenha participado de nenhum desafio, fato que somente pode ocorrer no segundo ou terceiro período de análise. O limiar de 75% foi definido pelos autores, uma vez que não foi possível encontrar na literatura valores que pudessem ser utilizados para tal finalidade. Por tratar-se de um trabalho preliminar, assume-se que esse valor seja justo para estudar o fenômeno, uma vez que esse valor baseia-se na distribuição dos desenvolvedores na plataforma. Além disso, entende-se que esta pode ser uma ameaça à validade.

No passo 4, foram analisados os dados referentes à classificação da especialidade. Verificou-se se houve "troca" ou "manutenção" de especialidade dos participantes comparando o período inicial de 6 meses com os períodos seguintes. Por meio desta comparação, uma análise descritiva dos dados foi conduzida, com o intuito de verificar se a hiperespecialização pode se manifestar no contexto deste trabalho.

Também verificou-se se a variação da quantidade de participações dos usuários que competiram ao longo dos três períodos. Para esta análise foi executado o teste estatístico ANOVA *One-Way Repeated Measures*. Esse teste foi utilizado para comparar três ou mais resultados oriundos da observação do mesmo grupo de amostras. No contexto

deste trabalho foram selecionados todos os usuários que participaram nos três períodos (incluindo os usuários não especialistas). Para isso, definiu-se a seguinte hipótese nula (H_0): a participação da população nos três semestres é igual com relação à quantidade de desafios participados.

O teste estatístico Chi-Square Test foi utilizado para avaliar a existência da relação entre o baixo número de participações com a desistência ou permanência na plataforma. Para este teste foram criados dois grupos com a quantidade de participação dos usuários no primeiro semestre. O primeiro grupo contempla a quantidade de contribuição dos participantes que continuaram na plataforma no segundo semestre, enquanto o segundo grupo contempla os participantes que não possuem contribuição no segundo semestre. A hipótese nula (H_0) é: a quantidade de participação nos desafios não está associada à permanência ou desistência dos usuários na plataforma.

4. Resultados

Como dito anteriormente, o objetivo deste trabalho é verificar se a hiperespecialização se manifesta na plataforma Topcoder em termos de tipo de desafio. Contudo, outros resultados chamaram a atenção durante a análise, então esta seção foi dividida em duas partes: a Seção 4.1 apresenta os resultados relativos à hiperespecialização; e a Seção 4.2 apresenta os demais resultados que auxiliam na compreensão do perfil de contribuição dos usuários de *crowdsourcing*.

4.1. Hiperespecialização

Dentre os 664 participantes analisados, apenas 98 (14% da população amostral) se mantiveram contribuindo ao longo dos três períodos (18 meses) do estudo. Dentre estas 98 amostras, 92 (93,8% dos participantes que permaneceram), **mantêm o mesmo padrão de contribuição** ao longo do período verificado. Esse resultado indica evidência de que a hiperespecialização pode se manifestar com relação ao tipo de desafio. A proporção de especialistas nos três períodos, dividido de acordo com o tipo de desafio foi: 8 usuários hiperespecialistas em desenvolvimento, 4 em design e 80 em ciência de dados.

Além do reportado acima, observou-se que alguns participantes (35) se ausentaram no segundo semestre da análise e retornaram no terceiro. Dentre estes 35, 32 (91,4%) foram classificados com a mesma especialidade em ambos os períodos, e os outros 3 mudaram de especialidade – os três foram classificados como especialistas em ciência de dados no primeiro semestre, e, no último, foram classificados como especialistas em desenvolvimento (2) e design (1).

Uma característica em relação aos usuários que se mantém contribuindo ao longo dos três períodos é a diferença na quantidade de contribuições realizadas por cada usuário. Para analisar esta característica, empregou-se o teste ANOVA, comparando a quantidade de participação nos três períodos. O resultado mostra que existe diferença na quantidade de participação dos usuários que seguiram contribuindo ($F=6,07$; $p\text{-value}=0,003$), rejeitando H_0 . Os resultados das multi-comparações – cujos $p\text{-values}$ foram ajustados usando o *Tukey method* – mostraram que a quantidade de participação dos usuários no primeiro período é diferente do segundo período ($t\text{-ratio}=2,48$; $p\text{-value}=0,04$). Observou-se ainda diferença na quantidade de participação entre o primeiro e o terceiro períodos ($t\text{-ratio}=3,36$; $p\text{-value}=0,002$). Entretanto, observou-se que não há evidência de que os valores para o segundo e terceiro período sejam diferentes ($t\text{-ratio}=0,881$; $p\text{-value}=0,653$).

Por meio desta análise foi possível verificar que os usuários que contribuem em todos os períodos possuem o pico de contribuição no primeiro semestre, e redução no número de contribuições no segundo período, mantendo-se constante no terceiro (Figura 2).

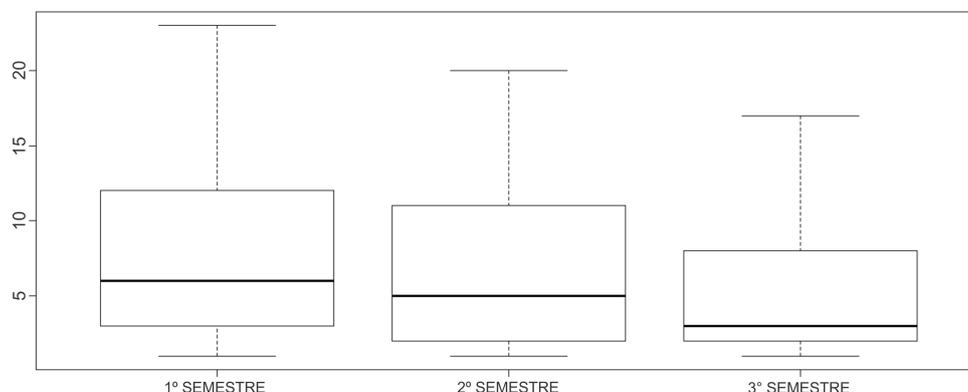


Figura 2. Distribuição das participações nos períodos verificados

4.2. Demais análises

Além da análise da hiperespecialização, o resultado que mais chamou a atenção foi o fato de cerca de 66% de toda a amostra possuir contribuições **apenas** no primeiro período verificado, indicando uma possível desistência de participação na plataforma. Essa fato corrobora a visão de Zanatta et al. (2017), em que os autores citam a dificuldade dos iniciantes em contribuir com a plataforma, já que no escopo deste trabalho, o primeiro período é definido a partir da primeira participação do usuário. Identificou-se que, dos 441 usuários que pararam de contribuir, 272 participaram de apenas um desafio. Para os outros 169 usuários que desistiram, observou-se uma variação entre duas e vinte e oito participações (mediana=3, desvio padrão=3,44). Essa característica pode indicar ao menos cinco potenciais situações: (i) não adequação dos usuários aos padrões da plataforma (dificuldade para encontrar as tarefas no perfil do usuário, problemas para interagir com a plataforma e com outros usuários entre outros); (ii) falta de conhecimento para a conclusão das tarefas; (iii) ineficiência dos métodos de treinamento propostos pela plataforma; (iv) os usuários atingiram seu objetivo – participar/treinar em alguma tecnologia específica ou ganhar a quantia de dinheiro; ou (v) os usuários buscavam ganhar dinheiro de maneira rápida e acabou não vencendo os primeiros desafios – investindo seu tempo sem ter o retorno financeiro esperado.

Por meio da análise da hiperespecialização pode-se observar a distribuição da quantidade de participação das amostras. A Figura 3 demonstra a diferença na quantidade de participação do primeiro semestre entre os usuários, sendo que, para efeito de melhor visualização, não são apresentados os *outliers*. Observando os boxplots foi possível verificar que, em geral, os usuários que param de contribuir possuem menos participações no primeiro semestre, do que os usuários que se mantêm ativos na plataforma.

Para validar a análise dos boxplots, e verificar se existe relação entre a quantidade de participação e a desistência/permanência executou-se o teste Chi-Square. O resultado do teste mostrou que a quantidade de desafios em que o usuário participou é um indicativo para desistência/permanência, rejeitando H_0 ($X^2=197.18$, $p\text{-value} < 0,001$). Contudo, outras análises devem ser conduzidas para melhor entendimento do fenômeno.

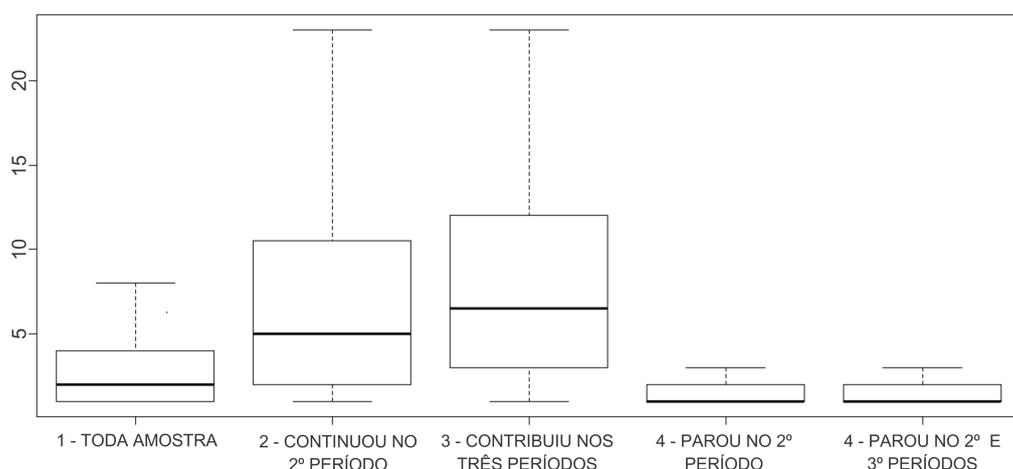


Figura 3. Distribuição das participações nos períodos verificados

5. Limitações e ameaças a validade

Uma possível ameaça à validade dos resultados está relacionada à escolha da população amostral. A atual coleção de dados conta com as participações de aproximadamente 350 mil dos mais de um milhão e cem mil usuários cadastrados na plataforma. Desta maneira, para contar com respaldo estatístico, o tamanho da população amostral foi construída com base no total de membros cadastrados na plataforma, porém a escolha aleatória limitou-se a totalidade dos usuários que estão na coleção de dados.

A análise preliminar conduzida no âmbito deste trabalho verifica a hiperespecialização por meio da classificação dos desafios que a plataforma propõe, entretanto existem outras abordagens, descritas na Seção 6, que podem indicar diferentes graus de hiperespecialização, devido à granularidade das classificações.

Uma das regras para que o usuário fosse elegível é a necessidade do mesmo ter participado de ao menos um desafio, para que essa participação fosse o ponto de partida do período a ser verificado. A escolha desta quantidade de desafios acarretou que, em 272 casos, os participantes possuíam somente um desafio participado, esse fato pode distorcer a análise da hiperespecialização. Em contrapartida, isto nos permitiu evidenciar a grande taxa de desistência dos participantes.

6. Conclusão

Este artigo apresentou um estudo exploratório sobre uma das possíveis formas de manifestação da hiperespecialização na plataforma Topcoder, uma das maiores plataformas de *crowdsourcing* para desenvolvimento do software. Os resultados mostraram evidências da existência da hiperespecialização em termos do tipo de tarefa escolhida pelos usuários. Verificou-se que, entre as pessoas que continuaram contribuindo nos três primeiros períodos de seis meses após sua primeira aparição, 94% sempre contribuem em tarefas de mesma classificação.

Além disso, o estudo exploratório indicou que muitos desenvolvedores iniciantes têm dificuldade em continuar competindo na plataforma, visto que muitos param de competir com seis meses ou até menos. Conseguir reverter essa situação é um achado im-

portante para a engenharia de software, pois a indústria poderá contar com um *pool* maior de trabalhadores, mais experientes e que podem construir sistemas de mais qualidade.

Como dito na Seção 3 investigou-se a hiperespecialização no contexto do tipo do desafio (desenvolvimento, design ou ciência de dados). Porém, pode-se investigar a manifestação da hiperespecialização considerando, por exemplo, as tecnologias utilizadas no desafio (C++, Java, AngularJS); e plataformas utilizadas no desafio (iOS, Android, Linux, Windows). Assim, como próximo passo, serão investigados outros modos de verificar a existência de hiperespecialização. Além disso, serão conduzidos outros trabalhos com o intuito de explorar diferentes perfis de contribuição dos usuários de *crowdsourcing*.

Também pretende-se explorar o restante do período de contribuição dos usuários, a fim de: (i) verificar se os usuários seguem contribuindo no mesmo padrão evidenciado neste trabalho; (ii) verificar se em algum momento as pessoas que param de contribuir acabam retornando; (iii) identificar os motivos de desistência dos usuários; (v) examinar a relação entre a quantidade de participações e a desistência dos usuários.

Referências

- Ambreen, T. and Ikram, N. (2016). A state-of-the-art of empirical literature of crowdsourcing in computing. In *ICGSE 2016*, pages 189–190. IEEE.
- Gadiraju, U. (2015). Make hay while the crowd shines: Towards efficient crowdsourcing on the web. In *24th WWW*, pages 493–497. ACM.
- Gray, M. L., Suri, S., Ali, S. S., and Kulkarni, D. (2016). The crowd is a collaborative network. In *19th ACM CSCW*, pages 134–147. ACM.
- Hosseini, M., Phalp, K., Taylor, J., and Ali, R. (2014). The four pillars of crowdsourcing: A reference model. In *RCIS Conference 2014*, pages 1–12. IEEE.
- Karim, M. R., Messinger, D., Yang, Y., and Ruhe, G. (2016). Decision support for increasing the efficiency of crowdsourced software development. *arXiv preprint*.
- LaToza, T. D. and van der Hoek, A. (2016). Crowdsourcing in software engineering: Models, motivations, and challenges. *IEEE software*, 33(1):74–80.
- Malone, T. W., Laubacher, R. J., and Johns, T. (2011). The age of hyperspecialization. *Harvard Business Review*, 89(7-8):56–+.
- Mao, K., Capra, L., Harman, M., and Jia, Y. (2015). A survey of the use of crowdsourcing in software engineering. *RN*, 15(01).
- Mao, K., Wang, Q., Jia, Y., and Harman, M. (2016). Prem: Prestige network enhanced developer-task matching for crowdsourced software development.
- Saremi, R. L. and Yang, Y. (2015). Dynamic simulation of software workers and task completion. In *2nd CSI-SE workshop*, pages 17–23. IEEE Press.
- Surowiecki, J. (2005). The wisdom of crowds: why the many are smarter than the few. london. *Abacus: New Edition*.
- Xie, H., Lui, J. C., Jiang, J. W., and Chen, W. (2014). Incentive mechanism and protocol design for crowdsourcing systems. In *52nd Allerton Conference*, pages 140–147. IEEE.
- Zanatta, A., Steinmacher, I., Machado, L., de Souza, C., and Prikladnicki, R. (2017). Barriers faced by newcomers to software-crowdsourcing projects. *IEEE Software*, 34(2):37–43.