

CLASSIFICAÇÃO DE COMUNIDADES DE ATENÇÃO ALTMÉTRICA NO X:

avaliando a acurácia de algoritmos sob diferentes variáveis

Danielle Pompeu Noronha Pontes

 <https://orcid.org/0000-0003-0036-6638>.

 dnoronha@uea.edu.br.

 Universidade de Brasília (UnB) |

 <https://ror.org/02xfp8v59> | Brasília, Brasil.

João de Melo Maricato

 <https://orcid.org/0000-0001-9162-6866>.

 jmmaricato@unb.br.

 Universidade de Brasília (UnB) |

 <https://ror.org/02xfp8v59> | Brasília, Brasil.


Eixo temático: Técnicas, Ferramentas e Infraestruturas

Modalidade: Resumo expandido

DOI: 10.22477/ix.ebbc.323

Resumo: A pesquisa analisa os algoritmos de inteligência artificial *Random Forest*, KNN e *Decision Tree* para identificar o modelo mais preciso na classificação das contas do X, visando deduzir tipos e categorias de perfis. O estudo, de natureza aplicada e com enfoque quantitativo, revela que o *Random Forest* obteve a melhor acurácia (71,77%) na classificação por “categoria do perfil”, enquanto o *Decision Tree* se destacou (64,78%) na classificação por “tipo de perfil”. Entretanto, os modelos estudados são considerados insuficientes para uma classificação robusta, sugerindo a necessidade de considerar fatores temporais e históricos para aprimorar os modelos de classificação.

Palavras-Chave: Altmétria. Acurácia. X. Twitter. Comunidade de atenção.



1 INTRODUÇÃO

Entender as comunidades de atenção e suas interações com a ciência é um dos interesses do campo da Altmétrie (Maricato; Manso, 2022) e a classificação dessas é necessidade premente. Ganham relevância os estudos que utilizam dados do X (antigo *Twitter*), para rastrear as características do usuário e os significados de suas interações com os objetos de pesquisa (Díaz-Faez; Bowman; Costas, 2019), incluindo estudos que visam distinguir contas automatizadas das não automatizadas (Morais; Digiam-pietri, 2021). Estudos apontam para o fato de que existem padrões que caracterizam as atividades científicas no X: área, origem geográfica e até data de publicação (Haustein, 2019).

Pesquisas apontam que há mais contas de indivíduos do que de organizações no X (Haustein, 2019; Tsou *et al.*, 2015). Dentro de uma rede de atenção altmétrica, as interações mais altas são de membros acadêmicos em comparação com o público em geral (Joubert; Costas, 2019). Segundo (Haustein, 2019), as principais motivações para os pesquisadores utilizarem essa rede social são: disseminar informações, estabelecer networking e estar atualizado com seus respectivos campos de pesquisa. No entanto, há indícios de resistência dos acadêmicos em se engajar com essas comunidades em mídia e nas redes sociais por receio de prejudicar sua reputação (Nicholas *et al.*, 2015) e devido a desconfiança em relação a procedência, qualidade e credibilidade das informações nas redes (Segado-Boj *et al.*, 2019).

Desta forma, o X não é uma plataforma usual na academia, em geral, sendo usado de forma passiva ou pouco frequente (Haustein, 2019). Em pesquisa sobre postagens no X sobre ciência na África do Sul, Joubert e Costas (2019) identificaram que usuários não acadêmicos postam conteúdo científico ocasionalmente. Pesquisadores, por outro lado, postam com mais frequência sobre ciência no X, seja por meio de postagens originais, usando hashtags ou fazendo menções a outras contas. Embora, segundo Barcelos e Maricato (2017), o X foi a rede social que apresentou, proporcionalmente, o maior engajamento dos autores com suas próprias pesquisas.

Segundo Maricato e Manso (2022), pesquisadores representam 11,8% dos que compartilham artigos no X, citando 10,9% dos artigos e totalizando 11,8% das menções. Somando docentes, pesquisadores e estudantes, perfis acadêmicos totalizam 21,3% dos perfis, 22,5% dos artigos e 21,4% das menções. (Haustein, 2019) registrou 22% das contas como pesquisadores, que incluem cientistas, professores e pesquisadores.

No que diz respeito ao volume de seguidores, Maricato e Manso (2022) apontam que as categorias de professores universitários (6%), estudantes (6%) e pesquisadores (5,9%) se destacam. Essas três categorias, todas elas associadas a instituições acadêmicas, correspondem a aproximadamente 18% do total de seguidores. Contudo, é importante ressaltar que, embora essas ocupações tenham relevância na divulgação de mensagens científicas, o engajamento da sociedade em geral e de ocupações não acadêmicas desempenham um papel ainda mais significativo na disseminação da ciência nas mídias sociais. Esses números destacam o potencial da altmetria para medir impactos além da academia.

O estudo realizado por Fang, Costas e Wouters (2022) analisou o envolvimento dos usuários do X com postagens acadêmicas que compartilham artigos científicos, examinando quatro tipos de interações: curtidas, repostagens, citações e respostas. Os autores descobriram que as curtidas são a forma mais comum de engajamento, representando 44% das interações acadêmicas, seguidas pelas repos-

tagens, que compreendem 36% do total. Por outro lado, menções e respostas, constituem, respectivamente, apenas 9% e 7% das interações no X para trabalhos acadêmicos.

Nishikawa-Pacher (2023) examinou o papel dos periódicos na rede altmétrica do X, utilizando dados de 3.485 contas pertencentes a uma amostra de 13.821 periódicos listados nos índices SCIE, SSCI e AHCI da *Web of Science*. Cerca de 25,2% dos periódicos têm presença no X, com uma média de 116 mensagens emitidas por ano por conta da editora e interação com outros usuários a cada dois a três *Tweets*. Aproximadamente 600 periódicos se autodenominam 'revisados por pares', enquanto 263 mencionam o impacto das citações em seus perfis. Os dados revelam uma grande heterogeneidade no comportamento das revistas científicas no X, com a presença de perfis fraudulentos criados por editores predatórios (Nishikawa-Pacher, 2023). Recomenda-se que as revistas estabeleçam suas contas oficiais para evitar a desinformação sobre descobertas científicas.

Segundo Haustein (2019), compreender que tipos de conteúdo acadêmico são difundidos no X, quem os divulga, quando e como ajudará a avaliar as métricas do X como indicadores de impacto válidos e a interpretar seu significado. Dentro deste contexto, entender qual a influência das categorias de perfil (classificadas entre social, acadêmico e profissional), e dos tipos de perfis (classificados em pessoal e institucional) na divulgação científica no X, diferenciá-los e identificá-los torna-se necessários para analisar sua atuação e sua influência no score altmetrico.

O propósito central deste estudo é avaliar a eficácia dos algoritmos de inteligência artificial, *Random Forest*, KNN e *Decision Tree*, na classificação das contas do X, tanto em termos de categorização dos públicos em segmentos sociais, acadêmicos ou profissionais, quanto na identificação do tipo de perfil adotado pelos usuários, conforme delineado por Maricato e Manso (2022). Em consonância com esses objetivos, são empregados os conjuntos de dados fornecidos pelos autores para testar a eficácia dos algoritmos em combinação com as variáveis pertinentes: o ano de ingresso no X, o número de postagens, o número de seguidores e o número de pessoas seguindo o perfil.


2 PROCEDIMENTOS METODOLÓGICOS

A metodologia utilizada pode ser descrita como de natureza aplicada, com enfoque quantitativo, de cunho exploratório e descritivo, utilizando-se de modelo experimental. O desenvolvimento desta pesquisa organiza o processo de mineração de dados em dois passos apresentados na Figura 1, sendo eles: (A) Seleção do *dataset* de treinamento; (B) Análise da acurácia de 3 algoritmos de classificação de aprendizagem de máquina.

Dataset de treinamento é o conjunto de dados que serão usados para a classificação, para então ser realizado o treinamento dos modelos propostos e a validação (Morais; Digiampietri, 2021). Durante a fase de seleção do *dataset* de treinamento, foi decidido empregar as variáveis presentes na base de dados obtida do estudo realizado por Maricato e Manso (2022). Essa mesma base de dados foi utilizada para avaliar a precisão dos algoritmos na classificação das contas, uma vez que os autores classificaram manualmente essas contas do X. Os perfis dos usuários do X que compartilharam os artigos foram cuidadosamente analisados pelos autores, levando em consideração o tipo de perfil (pessoal, institucional

e personagem) e a categoria do perfil (social, acadêmico e profissional), e incluindo informações como ocupação, área de trabalho, vínculos geográficos e institucionais. Os dados das contas dos usuários foram obtidos diretamente dos perfis do X, sendo que 2.456 contas foram classificadas pelos autores, estes dados foram utilizados para compor o *dataset* de treinamento desta pesquisa. Para classificação da categoria do perfil (social, acadêmico e profissional) foram utilizadas a totalidade de registros (dados de 2.456 contas), a classificação do tipo de perfil (pessoal, institucional) foram excluídas as contas que não possuíam ano (rotuladas como “sem ano identificado”) restando 2.117 contas.

Figura 1 - Representação gráfica dos procedimentos metodológicos adotados na pesquisa



Fonte: Dados da pesquisa (2024).

Foram realizados testes de acurácias (Figura 2) através de *Workflows* desenvolvidos na plataforma *Knime*¹ para o *dataset* de treinamento² considerando várias combinações dos conjuntos de variáveis ano, numtweets, seguindo e seguidores e aplicados em 3 algoritmos de classificação de aprendizagem de máquina a saber KNN, *Decision Tree* e *Random Forest*.

Foram realizados testes alterando o parâmetro de normalização de pontuação entre *Z-score*³ (Gaussiana) e a Normalização por escala decimal⁴ além da porcentagem de distribuição entre dados de treinamentos e de testes (70/30, 80/20), onde, considerando os 2.456 perfis utilizados para a análise por categoria de perfil, 70% corresponde a 1.719 perfis e 30% correspondem a 737 perfis, 80% corresponde a 1.965 perfis, 20% corresponde a 491 perfis e considerando os 2117 perfis usados na análise para tipo de perfil, 70% corresponde a 1.481 perfis e 30% correspondem a 636 perfis, 80% corresponde a 1.694 perfis, 20% corresponde a 423 perfis.


¹ *Knime* é uma plataforma para ciência de dados que permite a criação de modelos analíticos e serviços de dados.

² O *dataset* de treinamento foi dividido em dados de categorias e dados de tipos de perfis com base na seleção de colunas realizadas nos nós *Column Filter* do *Workflow*.

³ O *Z-score* realiza a transformação linear tal que os valores em cada coluna são distribuídos em Gauss (0,1), ou seja, a média é 0,0 e o desvio padrão é 1,0.

⁴ Na normalização por escala decimal o valor máximo em uma coluna (positivo e negativo) é dividido j vezes por 10 até que seu valor absoluto seja menor ou igual a 1. Todos os valores na coluna são então divididos por 10 elevado à potência de j.

Figura 2 - Workflow para avaliação da acurácia desenvolvido através do *Knime*



Fonte: Dados da pesquisa (2024).

O Workflow consiste em 9 etapas onde, a 1ª é responsável pelo carregamento do *dataset*, as etapas 2 (categoria do perfil) e 6 (tipo de organização) separam as colunas das variáveis testadas (esse procedimento foi realizado 4 vezes para testar as variáveis destacadas na Tabela 1). As etapas 3, 4, 5, 7, 8 e 9 implementam os algoritmos de Inteligência Artificial testados.

3 RESULTADOS E DISCUSSÕES

Os resultados (Tabela 1) indicam a precisão (acurácia) alcançada por diferentes algoritmos de classificação ao tentar prever o tipo de perfil e a categoria do perfil de usuários com base nos dados fornecidos no *dataset* de treinamento. A precisão é uma medida que indica a proporção de casos corretamente classificados em relação ao total de casos.

Tabela 1 - Resultados das avaliações das acurácias

VARIÁVEIS	KNN	DECISION TREE	RANDOM FOREST
CATEGORIA PERFIL			
(numtweets, seguindo, seguidores)	68,71 (Z-SCORE,K9,70/30)	69,82 (Z-SCORE,70/30)	67,35 (Z-SCORE,70/30)
(Seguindo, seguidores)	66,8 (Z-SCORE,K9,80/20)	68,9 (Z-SCORE,80/20)	65 (Z-SCORE,80/20)
(ano, seguindo, seguidores)	68,11 (Z-SCORE k6, 70/30)	68,25 (Z-SCORE, 70/30)	68,47 (Z-SCORE, 70/30)
(ano, numtweets, seguindo, seguidores)	71,5 (Z-SCORE k6,70/30)	71,37 (Z-SCORE,70/30)	71,77 (Z-SCORE,70/30)
(ano,mediapostsdia,numtweets, seguindo, seguidores)	69,49 (k=6,Z-SCORE,70/30)	69,18 (Z-SCORE, 70/30)	67,3(Z-SCORE, 70/30)
(ano,mediapostsdia,numdiasX,numtweets, seguindo, seguidores)	67,29 (k=6,Z-Score,70/30)	68,08 (norm, 70/30)	68,71(norm, 70/30)
TIPO PERFIL			
(numtweets, seguindo, seguidores)	55,83 (Z-SCORE,K9,70/30)	51,57 (Z-SCORE,70/30)	51,30 (Z-SCORE,70/30)
(seguindo, seguidores)	43 (Z-SCORE,K8,70/30)	52,67 (Z-SCORE,70/30)	50,34 (Z-SCORE,70/30)
(ano seguindo, seguidores)	46,95 (Z-SCORE k6, 70/30)	50,8 (Z-SCORE,70/30)	51,6 (Z-SCORE,70/30)
(ano, numtweets, seguindo, seguidores)	58,88 (Norm, k7, 70/30)	62,95 (Norm, 70/30)	62,55 (Norm, 70/30)
(ano,mediapostsdia,numtweets, seguindo, seguidores)	58,17 (k=6, Norm,70/30)	63,99 (Norm, 70/30)	64,46 (Norm,70/30)
(ano,mediapostsdia,numdiasX,numtweets, seguindo, seguidores)	62,10 (k=6, Norm,70/30)	64,78 (Norm, 70/30)	64,38 (Norm,70/30)

Fonte: Dados da pesquisa (2024).

Na Tabela 1 observa-se que o melhor desempenho foi alcançado pelo algoritmo *Random Forest*, que obteve uma acurácia de 71,77% para previsão da **categoria do perfil**. Isso significa que, ao utilizar variáveis como ano de entrada no X, número de seguidores, número de amigos (seguindo) e número total de tweets, o algoritmo *Random Forest* foi capaz de classificar corretamente aproximadamente 71,77% dos perfis no *dataset* de treinamento. Observando que esse conjunto de variáveis alcançou as maiores acurácias para os algoritmos KNN (71,5%), *Decision Tree* (71,37%) e *Random Forest* (71,77%), conclui-se que essas variáveis são mais relevantes na classificação das contas do X em diferentes categorias de perfil. O algoritmo *Random Forest* foi parametrizado para dividir o *dataset* em duas bases, na proporção de 70% para treinamento e 30% para teste e utilizando z-score para normalização dos dados. A métrica de *Cohen's Kappa*, indicando a concordância entre a classificação prevista e a real, foi de 0,21%, sugerindo um nível de concordância moderado. Considerando a divisão do *Dataset* de Maricato e Manso (2022) com base na porcentagem de distribuição entre dados de treinamentos e de testes (70/30) definida através da parametrização do nó *Partitioning*, foram testados 737 perfis, correspondente aos 30% da base de teste, dos quais, **529** perfis foram classificados corretamente, enquanto 208 foram classificados incorretamente, resultando em uma taxa de erro de 28,223%. Este desempenho destaca a importância das variáveis utilizadas na determinação da categoria de perfil, no entanto, é necessário um estudo mais aprofundado para avaliar a generalização desses resultados em diferentes conjuntos de dados e contextos.

Os resultados indicam que, ao tentar prever o **tipo de perfil** com base nos dados fornecidos, o algoritmo de *Decision Tree* teve o melhor desempenho. Isso significa que, utilizando variáveis como o ano de entrada no X, média de *posts* por dia, número total de dias de participação no X, o número de seguidores, o número de amigos (aqueles que o perfil segue) e o total de *Tweets*, o algoritmo conseguiu classificar corretamente cerca de 64,78% dos perfis no conjunto de treinamento. O algoritmo foi parametrizado com uma divisão de 70% do *dataset* sendo utilizado para treinamento e 30% (636 perfis) para teste, desta vez, utilizando normalização dos dados. O coeficiente de *Cohen's Kappa*, foi de 0,359%, sugerindo um nível moderado de concordância. Dos dados analisados, 412 perfis foram classificados corretamente, enquanto 224 foram classificados incorretamente, resultando em uma taxa de erro de 35,22%. Esses resultados sugerem que as variáveis utilizadas têm uma influência significativa na deter-

minação do tipo de perfil. *Decision Tree*, como algoritmo, foi capaz de utilizar essas variáveis de forma eficaz para fazer previsões precisas.

As acurácias da classificação de categoria de perfil e tipo de perfil sugerem a necessidade de estudos mais aprofundados para definir essas classificações por meio de IA. Notavelmente, as variáveis média de *posts* por dia e número de dias no *X* tiveram um impacto negativo na acurácia da categoria de perfil. Quanto à classificação do tipo de perfil, as acurácias foram significativamente baixas, destacando a importância de investigações adicionais. A variável ano, e consequentemente o número de dias no *X* (derivado do ano de entrada), foram identificadas como influenciadoras da acurácia.

4 CONCLUSÕES

Em conclusão, este estudo destaca a complexidade na classificação robusta da categoria e do tipo de perfil das contas do *X*, baseando-se exclusivamente em variáveis relacionadas ao usuário. A análise revela que, das seis variáveis consideradas, aquelas mais significativas para a classificação incluem o número de contas seguidas, o número de seguidores, o ano de criação da conta e o total de *Tweets* publicados. Observa-se que a variável “Ano” demonstra uma relevância ainda maior do que o número de *Tweets* na predição do tipo de perfil. Esses resultados apontam para a necessidade de uma abordagem mais abrangente e multifacetada na classificação de perfis em redes sociais, considerando não apenas as interações diretas, mas também fatores temporais e históricos que podem influenciar significativamente a natureza e o comportamento das contas.


O modelo de *Random Forest* com as variáveis (ano, *numtweets*, *seguindo*, *seguidores*) apresenta uma acurácia razoável, mas ainda há espaço para melhorias, especialmente em termos de aumentar a concordância entre as previsões e os rótulos reais, bem como reduzir a taxa de erro. Diferentes algoritmos apresentam resultados variados. Explorar outros algoritmos de aprendizado de máquina, como SVM (*Support Vector Machines*) ou redes neurais, pode ser uma estratégia para melhorar a acurácia dos modelos.

Para pesquisas futuras, é sugerido explorar outras características ou combinações existentes que possam melhor capturar os padrões nos dados e, consequentemente, aprimorar a acurácia dos modelos de classificação de usuários. Por exemplo, características como a razão entre seguidores e seguindo podem fornecer insights adicionais valiosos para a classificação de perfis, assim como a análise da descrição do perfil ou o sentimento das postagens. Sugere-se, também, novos testes que utilizem outras variáveis baseadas em aspectos Temporais⁵, de Conteúdo⁶ e de Sentimento⁷ possam ser relevantes para aumentar a acurácia dos algoritmos citados para a classificação das contas. Outra possibilidade de pesquisa é replicar o método aqui proposto em outras redes sociais tais como Instagram e Facebook.

⁵ Atividade do usuário durante diferentes intervalos de tempo considerando a quantidade de *posts* por dia.


⁶ O tipo de linguagem utilizada, comprimento das mensagens e a entropia do texto sendo publicado.

⁷ A atitude ou o humor de uma conversa ou mensagem.



REFERÊNCIAS

- BARCELOS, Janinne; MARICATO, João de Melo. Menções sobre a produção acadêmica nas mídias sociais: estudo altmétrico de visibilidade e engajamento público com artigos da scientometrics. *In: ENCONTRO NACIONAL DE PESQUISA EM CIÊNCIA DA INFORMAÇÃO*, 18., 2017, Marília. **Anais [...]**. Marília: Ancib, 2017. p. 1-16.
- DÍAZ-FAES, Adrián A.; BOWMAN, Timothy D.; COSTAS, Rodrigo. Towards a second generation of 'social media metrics': Characterizing Twitter communities of attention around science. **PLoS ONE**, San Francisco, v. 14, n. 5, p. 1–18, May 2019. DOI: <https://doi.org/10.1371/journal.pone.0216408>. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0216408>. Acesso em: 10 jan. 2024.
- FANG, Zhichao; COSTAS, Rodrigo; WOUTERS, Paul. User engagement with scholarly tweets of scientific papers: a large-scale and cross-disciplinary analysis. **Scientometrics**, Budapest, v. 127, n. 8, p. 4523–4546, July 2022. DOI: <https://doi.org/10.1007/s11192-022-04468-6>. Disponível em: <https://link.springer.com/article/10.1007/s11192-022-04468-6>. Acesso em: 11 jan. 2024.
- HAUSTEIN, Stefanie. Scholarly twitter metrics. *In: GLÄNZEL, Wolfgang; MOED, Henk F.; SCHMOCH, Ulrich; THELWALL, Mike (ed.). Springer Handbook of Science and Technology Indicators*. [S. l.]: Springer Handbooks, 2019. p. 729–760. DOI: https://doi.org/10.1007/978-3-030-02511-3_28. Disponível em: https://link.springer.com/chapter/10.1007/978-3-030-02511-3_28. Acesso em: 15 jan. 2024.
- JOUBERT, Marina; COSTAS, Rodrigo. Getting to Know Science Tweeters: A Pilot Analysis of South African Twitter Users Tweeting about Research Articles. **Journal of Altmetrics**, [S. l.], v. 2, n. 1, p. 1-14, May 2019. DOI: <https://doi.org/10.29024/joa.8>. Disponível em: <https://il-j-ja.ubiquityjournal.website/articles/10.29024/joa.8>. Acesso em: 10 jan. 2024.
- MARICATO, João de Melo; MANSO, Bruno Lara de Castro. Characterization of the communities of attention interacting with scientific papers on Twitter: altmetric analysis of a Brazilian University. **Scientometrics**, Budapest, v. 127, n. 7, p. 3815–3835, June 2022. DOI: <https://doi.org/10.1007/s11192-022-04442-2>. Disponível em: <https://link.springer.com/article/10.1007/s11192-022-04442-2>. Acesso em: 5 jan. 2024.
- MORAIS, Daniel Marques Gomes de; DIGIAMPIETRI, Luciano Antonio. Methods and Challenges in Social Bots Detection: A Systematic Review. *In: BRAZILIAN SYMPOSIUM ON INFORMATION SYSTEMS*, 17., 2021, Uberlândia Brazil. **Proceedings [...]**. New York: Association for Computing Machinery, 2021. p. 1-8. Disponível em: <https://dl.acm.org/doi/10.1145/3466933.3466973>. Acesso em: 30 jan. 2024.
- NICHOLAS, David; HERMAN, Eti; JAMALI, Hamid; RODRÍGUEZ-BRAVO, Blanca; BOUKACEM-ZEGHMOURI, Cherifa; DOBROWOLSKI, Tom; POUCHOT, Stephanie. New ways of building, showcasing, and measuring scholarly reputation. **Learned Publishing**, [S. l.], v. 28, n. 3, p. 169–183, July 2015. DOI: <https://doi.org/10.1087/20150303>. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1087/20150303>. Acesso em: 10 jan. 2024.
- NISHIKAWA-PACHER, Andreas. The Twitter accounts of scientific journals: a dataset. **Insights: the UKSG Journal**, [S. l.], v. 36, n. 1, p. 1-15, Jan. 2023. DOI: <https://doi.org/10.1629/uksg.593>. Disponível em: <https://insights.uksg.org/articles/10.1629/uksg.593>. Acesso em: 7 fev. 2024.



SEGADO-BOJ, Francisco; DÍAZ-CAMPO, Jesús; FERNÁNDEZ-GÓMEZ, Erika; CHAPARRO-DOMÍNGUEZ, María-Ángeles. Spanish academics and social networking sites: Use, non-use, and the perceived advantages and drawbacks of Facebook, Twitter, LinkedIn, ResearchGate, and Academia.edu. **First Monday**, Chicago, v. 24, n. 5, 2019. DOI: <https://doi.org/10.5210/fm.v24i5.7296>. Disponível em: <https://journals.uic.edu/ojs/index.php/fm/article/view/7296>. Acesso em: 10 jan. 2024.

TSOU, Andrew; BOWMAN, Tim; GHAZINEJAD, Ali; SUGIMOTO, Cassidy. Who tweets about science? *In*: INTERNATIONAL SOCIETY OF SCIENTOMETRICS AND INFORMETRICS CONFERENCE, 15., 2015, Istanbul. **Proceedings [...]**. [S. l.]: Bogaziçi University, 2015. p. 95–100. Disponível em: <https://www.issi-society.org/publications/issi-conference-proceedings/proceedings-of-issi-2015>. Acesso em: 2 fev. 2024.