


Francisco Odécio Sales
(Organizador)

CIÊNCIAS EXATAS e da terra:


Observação, formulação e previsão 2



Francisco Odécio Sales
(Organizador)

CIÊNCIAS EXATAS e da terra:

Observação, formulação e previsão 2



Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Bruno Oliveira

Camila Alves de Cremo

Daphynny Pamplona

Gabriel Motomu Teshima

Luiza Alves Batista

Natália Sandrini de Azevedo

Imagens da capa

iStock

Edição de arte

Luiza Alves Batista

2022 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2022 Os autores

Copyright da edição © 2022 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição Creative Commons. Atribuição-Não-Comercial-Não-Derivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial**Ciências Exatas e da Terra e Engenharias**

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto

Profª Drª Alana Maria Cerqueira de Oliveira – Instituto Federal do Acre

Profª Drª Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie

Profª Drª Ana Paula Florêncio Aires – Universidade de Trás-os-Montes e Alto Douro

Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás

Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná



Prof. Dr. Cleiseano Emanuel da Silva Paniagua – Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Profª Drª Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Profª Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho
Prof. Dr. Juliano Bitencourt Campos – Universidade do Extremo Sul Catarinense
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Profª Drª Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá
Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora
Prof. Dr. Miguel Adriano Inácio – Instituto Nacional de Pesquisas Espaciais
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Priscila Tessmer Scaglioni – Universidade Federal de Pelotas
Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista



Ciências exatas e da terra: observação, formulação e previsão 2

Diagramação: Bruno Oliveira
Correção: Mariane Aparecida Freitas
Indexação: Amanda Kelly da Costa Veiga
Revisão: Os autores
Organizador: Francisco Odécio Sales

Dados Internacionais de Catalogação na Publicação (CIP)

C569 Ciências exatas e da terra: observação, formulação e previsão 2 / Organizador Francisco Odécio Sales. – Ponta Grossa - PR: Atena, 2022.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-5983-993-3

DOI: <https://doi.org/10.22533/at.ed.933221104>

1. Ciências exatas. I. Sales, Francisco Odécio (Organizador). II. Título.

CDD 507

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

Atena Editora
Ponta Grossa – Paraná – Brasil
Telefone: +55 (42) 3323-5493
www.atenaeditora.com.br
contato@atenaeditora.com.br



Atena
Editora
Ano 2022

DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao artigo científico publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que os artigos científicos publicados estão completamente isentos de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.



DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.



APRESENTAÇÃO

A coleção “Ciências exatas e da terra: Observação, formulação e previsão 2” é uma obra que objetiva uma profunda discussão técnico-científica fomentada por diversos trabalhos dispostos em meio aos seus 20 capítulos. Esse 2º volume abordará de forma categorizada e interdisciplinar trabalhos, pesquisas, relatos de casos e/ou revisões que nos transitam vários caminhos das Ciências exatas e da Terra.

Tal obra objetiva publicizar de forma objetiva e categorizada estudos e pesquisas realizadas em diversas instituições de ensino e pesquisa nacionais e internacionais. Em todos os capítulos aqui expostos a linha condutora é o aspecto relacionado às Ciências Naturais, tecnologia da informação, ensino de ciências e áreas afins correlatos ao locus cultural.

Temas diversos e interessantes são deste modo, discutidos aqui com a proposta de fundamentar o conhecimento de acadêmicos, mestres e todos aqueles que de alguma forma se interessam por inovação, tecnologia, ensino de ciências e demais temas. Possuir um material que demonstre evolução de diferentes campos da engenharia, ciência e ensino de forma temporal com dados geográficos, físicos, econômicos e sociais de regiões específicas do país é de suma importância, bem como abordar temas atuais e de interesse direto da sociedade.

Deste modo a obra a seguir apresenta uma profunda e sólida fundamentação teórica bem com resultados práticos obtidos pelos diversos professores e acadêmicos que desenvolvem seu trabalho de forma séria e comprometida, apresentados aqui de maneira didática e articulada com as demandas atuais. Sabemos o quão importante é a divulgação científica, por isso evidenciamos também a estrutura da Atena Editora capaz de oferecer uma plataforma consolidada e confiável para estes pesquisadores exporem e divulguem seus resultados.


Francisco Odécio Sales

SUMÁRIO

CAPÍTULO 1..... 1

A BNCC EM TEMPO DE ENSINO REMOTO DE FÍSICA


Mutumbua José Ferrão Manuel
Sermos Domingos da Conceição
Antonio Luan Ferreira Eduardo
Aurélio Wildson Teixeira de Noronha

 <https://doi.org/10.22533/at.ed.9332211041>

CAPÍTULO 2..... 6

A MINERAÇÃO E O USO DOS MINERAIS EM ELEMENTOS DO COTIDIANO: O COMPUTADOR


Rafaela Baldi Fernandes
Tháís Figueiredo de Pinho

 <https://doi.org/10.22533/at.ed.9332211042>

CAPÍTULO 3..... 18

ACELERANDO O ALGORITMO K-MEANS – PRINCIPAIS PROPOSTAS


Marcelo Kuchar Matte
Maria do Carmo Nicoletti

 <https://doi.org/10.22533/at.ed.9332211043>

CAPÍTULO 4..... 29

AMBIENTES CÁRSTICOS: CRIPTOCARSTE OU EPICARSTE?


Alessandra Mendes Carvalho Vasconcelos
Cristiane Valéria de Oliveira
Joel Georges Marie Andre Rodet
Evelyn Aparecida Mecenero Sanchez
Gislaine Amorés Battilani
Ana Clara Mendes Caixeta

 <https://doi.org/10.22533/at.ed.9332211044>

CAPÍTULO 5..... 42

ANÁLISE DOS ASPECTOS CLIMÁTICOS DA CIDADE DE MACAPÁ-AP


Gabriel Brito Costa
Duany Thainara Corrêa da Silva
Ana Caroline da Silva Macambira
Letícia Victória Santos Matias

 <https://doi.org/10.22533/at.ed.9332211045>

CAPÍTULO 6..... 55

APLICANDO O DESIGN THINKING NOS SISTEMAS DE INFORMAÇÕES


Jonnathan Alves Teixeira
Fellipe Henrique Alves de Paula
Reane Franco Goulart

 <https://doi.org/10.22533/at.ed.9332211046>

CAPÍTULO 7..... 61

AVALIAÇÃO DE DESGASTE ENTRE TINTA NATURAL E USUAL, COM BASE EM TINTA DE TERRA: MEDIÇÃO DE REFLETÂNCIA, UMIDADE E DESGASTE

Guilherme Silveira Simões
Raduan Krause Lopes
Jayne Carlos Piovesan
Leandro Nascimento Soares Silva
Henrique Figueiredo da Silva
Luiz Henrique Alves dos Santos
Daniel Oliveira de Lima
Daniel Rodrigues dos Silva
Beatriz Ferreira França
Mikaele Costa Lairana
Matheus Felipe Martins Gelpke
Ingridy Maria Duarte Cabral

 <https://doi.org/10.22533/at.ed.9332211047>

CAPÍTULO 8..... 71

CONTRIBUIÇÕES DO JOGO PARA A APRENDIZAGEM DOS NÚMEROS INTEIROS E ASPECTOS DO DESENVOLVIMENTO HUMANO: UMA PRÁTICA COM ALUNOS DO 7º ANO DO ENSINO FUNDAMENTAL


Silvana Cocco Dalvi
Adriana da Conceição Tesch
Andressa Côco Lozorio
Regiane Giori
Maria Carolina Salvador Callegario
Regina Célia da Silva
Erivelton Cunha
Sebastião Thezolin

 <https://doi.org/10.22533/at.ed.9332211048>

CAPÍTULO 9..... 82

DESAFIOS DAS AULAS REMOTAS E DESAFIOS TECNOLÓGICO NO ENSINO DA FÍSICA

Faria Cusseta Samuel Francisco
Hamilton Francisco Catraio Nhime
Antonio Luan Ferreira Eduardo
Aurélio Wildson Teixeira de Noronha


 <https://doi.org/10.22533/at.ed.9332211049>

CAPÍTULO 10..... 87

DESENVOLVIMENTO DE UM KIT DIDÁTICO PARA ESTUDOS DE RESISTÊNCIA DOS MATERIAIS, COM APLICAÇÃO NA ENGENHARIA DE PRODUÇÃO

Paulo Urbano Ávila
Luiz Carlos de Campos
Oscar João Abdounur

José Antonio Siqueira Dias
Manuel Antonio Pires Castanho

 <https://doi.org/10.22533/at.ed.93322110410>

CAPÍTULO 11..... 108

EL ROL DEL CIUDADANO EN EL USO DE ENERGÍAS RENOVABLES EN MÉXICO, PARA CONSOLIDAR PROCESOS DE DESARROLLO SOSTENIBLE


Leticia Peña Barrera
Herrera, L.

 <https://doi.org/10.22533/at.ed.93322110411>

CAPÍTULO 12..... 118

ESTUDO DO MÉTODO DE LIOFILIZAÇÃO COMO ALTERNATIVA DE CONSERVAÇÃO DE LEITE FLUÍDO NO DESENVOLVIMENTO DE MATERIAL DE REFERÊNCIA PARA ENSAIO DE PROFICIÊNCIA FÍSICO-QUÍMICO


Marina Zuffo
Maicon Rodrigo Zangalli
Joseane Cristina Bassani

 <https://doi.org/10.22533/at.ed.93322110412>

CAPÍTULO 13..... 125

ESTUDOS ENVOLVENDO BASE DE SCHIFF EM SISTEMAS BIOLÓGICOS

Solange de Oliveira Pinheiro
Giovana Mouta Paiva
Micael Estevão Pereira de Oliveira
Daniela Ribeiro Alves
Guida Hellen Mota do Nascimento
João Batista de Andrade Neto
Wildson Max Barbosa da Silva

 <https://doi.org/10.22533/at.ed.93322110413>

CAPÍTULO 14..... 136

GEOPARQUE SERRA DO SINCORÁ: ESTÁGIO ATUAL DA CRIAÇÃO E IMPLEMENTAÇÃO DE UM GEOPARQUE ASPIRANTE NA PORÇÃO CENTRAL DO ESTADO DA BAHIA

Renato Pimenta de Azevedo
Ricardo Galeno Fraga de Araujo Pereira






 <https://doi.org/10.22533/at.ed.93322110414>

CAPÍTULO 15..... 147

ILHAS DE CALOR URBANA NA CIDADE DE FLORIANÓPOLIS-SC A PARTIR DE IMAGENS DO SATÉLITE LANDSAT

Natacha Pires Ramos
Renato Ramos da Silva

 <https://doi.org/10.22533/at.ed.93322110415>

CAPÍTULO 16.....	159
O MIDDLEWARE EMSS: UMA ARQUITETURA DE FOG COMPUTING EM CIDADES INTELIGENTES	
Sediane C. L. Hernandez Marcelo Eduardo Pellenz Alcides Calsavara	
 https://doi.org/10.22533/at.ed.93322110416	
CAPÍTULO 17.....	174
PRÁTICA VIRTUAL: MAGNETOSTÁTICA	
Mutumbua José Ferrão Manuel Faria Cusseta Samuel Francisco Aurélio Wildson Teixeira de Noronha	
 https://doi.org/10.22533/at.ed.93322110417	
CAPÍTULO 18.....	185
PRÁTICA VIRTUAL: EFEITO FOTOELÉTRICO	
Faria Cusseta Samuel Francisco Mutumbua José Ferrão Manuel Aurélio Wildson Teixeira de Noronha	
 https://doi.org/10.22533/at.ed.93322110418	
CAPÍTULO 19.....	197
SEQUÊNCIA DE FIBONACCI: ALGUNS RESULTADOS E APLICAÇÕES NAS CIÊNCIAS NATURAIS	
Francisco Odécio Sales	
 https://doi.org/10.22533/at.ed.93322110419	
CAPÍTULO 20.....	205
UN ESTUDIO SOBRE EL DESEMPEÑO ACADÉMICO EN ESTUDIANTES QUE CURSAN LA MATERIA DE MATEMÁTICAS DOS HORAS DIARIAS EN LA UNIVERSIDAD DE SONORA	
Alejandrina Bautista Jacobo	
 https://doi.org/10.22533/at.ed.93322110420	
SOBRE O ORGANIZADOR.....	211
ÍNDICE REMISSIVO.....	212

ACELERANDO O ALGORITMO K-MEANS – PRINCIPAIS PROPOSTAS

Data de aceite: 01/04/2022

Marcelo Kuchar Matte

Instituto Federal de Mato Grosso do Sul
Jardim, MS
<http://lattes.cnpq.br/2578744164817417>

Maria do Carmo Nicoletti

Centro Universitário Campo Limpo Paulista
(UNIFACCAMP)
Campo Limpo Paulista, SP
<http://lattes.cnpq.br/6454154048263145>

RESUMO: O objetivo do algoritmo k-Means é o de particionar um conjunto de instâncias de dados em k grupos (k clusters), sendo k um parâmetro usualmente fornecido pelo usuário. Apesar de eficiente na indução de um conjunto (clustering) de k grupos o k-Means padrão tem algumas deficiências e.g., quando o volume de instâncias de dados a ser processado é alto, o algoritmo pode ter um elevado custo computacional até o seu término. Esse artigo apresenta uma revisão de estratégias propostas na literatura para contornar algumas características do algoritmo com o objetivo de acelerar o seu processamento.
PALAVRAS-CHAVE: aprendizado de máquina, agrupamentos, k-means, desigualdade triangular.

ACCELERATING THE K-MEANS ALGORITHM – MAIN PROPOSALS

ABSTRACT: The goal of the k-Means algorithm is to partition a set of data instances into k clusters, where k is a parameter usually supplied

by the user. Despite being efficient in inducing a set (clustering) of k clusters, the standard k-Means has some deficiencies, e.g., when the volume of data instances to be processed is high, the algorithm may have a high computational cost until its completion. This paper presents a review of strategies proposed in the literature to circumvent some characteristics of the algorithm with the objective of speeding up its processing.

KEYWORDS: machine learning, clustering, k-means, triangular inequality.

1 | CONSIDERAÇÕES INICIAIS

Apesar da dificuldade de definir exatamente o conceito de Inteligência Artificial (IA), pode ser verificado junto à literatura associada que IA, como área de conhecimento, não se apresenta como uma área confinada e é subsidiada por um vasto conjunto de áreas de conhecimento, entre elas Matemática, Estatística, Psicologia, Fisiologia, Educação, Reconhecimento de Padrões, Processamento de Língua Natural, entre outras. Nos dias de hoje já é possível vislumbrar algumas de suas áreas de aplicação que, via de regra, têm em comum o objetivo de fazer com que computadores aumentem sua performance na realização de determinadas tarefas, sem a interferência humana. A capacidade de computadores de não apenas aumentarem seus desempenhos em tarefas, mas também aprenderem durante o processo é caracterizada como Aprendizado de Máquina (AM).

É importante lembrar, entretanto, que o processo de aprendizado realizado por seres humanos é uma área de investigação sobre a qual a ciência tem investido em estudos e pesquisa por um longo período de tempo sem, entretanto, conclusões definitivas. A comunidade científica ao longo das últimas décadas, mesmo sem a compreensão ampla de processos de aprendizado humano, mas vislumbrando suas potencialidades, tem procurado fomentar o desenvolvimento de processos de aprendizado automático por computadores e/ou máquinas. Geralmente tais processos são subsidiados por propostas de estratégias e de novos algoritmos que viabilizam algumas formas de aprendizado automático. Por meio da implementação de técnicas e algoritmos de AM alguns dos processos de aprendizado podem ser concretizados e.g., processos de classificação. A inferência lógica indutiva é o fundamento teórico que subsidia a área de AM, que busca a partir de um conjunto de instâncias de dados específicas, generalizar uma expressão de conceito que consiga caracterizar novas instâncias de dados ou, então, de agrupá-las de maneira a organizá-las de acordo com algum critério específico.

O conjunto de instâncias de dados fornecido como entrada a um algoritmo indutivo de AM é usualmente chamado de conjunto de treinamento. A representação das instâncias do conjunto de treinamento, na dependência de ter (ou não) uma informação associada identificada como classe, de certa forma colabora na identificação do tipo do algoritmo de AM adequado para um determinado conjunto de instâncias. Algoritmos que fazem uso da informação fornecida pelas classes associadas às instâncias de dados são geralmente chamados de algoritmos supervisionados. Algoritmos que não utilizam a informação da classe ou, então, que foram propostos com o intuito de apenas serem agrupadores de subconjuntos de instâncias do conjunto original de instâncias fornecido, são caracterizados como algoritmos não-supervisionados [Theodoridis & Koutroumbas 2009]. Dentre os algoritmos não-supervisionados prevalecem os algoritmos de agrupamento e, dentre eles, o k-Means [Lloyd 1957] tem se mostrado um dos mais populares. O uso de algoritmos de agrupamento pode ser conveniente em aplicações computacionais do mundo real, particularmente naquelas que envolvem análise exploratória de relações entre instâncias de dados, AM, recuperação de documentos, segmentação de imagens, etc. Agrupamentos são particularmente apropriados para exploração de inter-relações entre instâncias de dados e basicamente usam apenas informações nas descrições das instâncias.

Algoritmos de agrupamentos buscam descobrir grupos naturais em conjuntos de instâncias por meio de técnicas/medidas estatísticas, fazendo comparações quantitativas de atributos que descrevem instâncias. Jain, em [Jain 2010, pp. 652], define operacionalmente agrupamento: “dado um conjunto contendo N instâncias de dados, encontrar k grupos de instâncias, tendo por base uma medida de similaridade entre instâncias, de maneira que instâncias que pertencem ao mesmo grupo sejam semelhantes, enquanto que instâncias que pertencem a grupos distintos não sejam semelhantes”.

Uma das dificuldades associadas ao uso de algoritmos de agrupamento é a

determinação do número (k) de grupos que irão compor o agrupamento. Tal número deveria ser aquele que, supostamente, melhor refletisse a organização das instâncias de dados. Como raramente o valor de k é conhecido na prática, a maioria dos algoritmos de agrupamento é projetada para induzir k grupos em que k um valor pré-definido usualmente determinado por um especialista do domínio de conhecimento dos dados a serem agrupados.

Existem também os algoritmos conhecidos como semissupervisionados que, alternativamente, utilizam técnicas de aprendizado supervisionado e não supervisionado para conduzirem o processo de aprendizado. O objetivo da pesquisa na área de aprendizado semissupervisionado é o de utilizar informações contidas em instâncias com classes associadas e em instâncias sem classes associadas, e investigar maneiras de como essa combinação de informações pode colaborar com o processo de aprendizado, bem como o de projetar algoritmos eficientes que implementem tal combinação [Chapelle et al. 2006].

Desde a sua proposta o k -Means tem também sofrido inúmeras críticas, com relação a algumas de suas características. Esse artigo é uma extensão do trabalho apresentado em evento descrito em [Matte & Nicoletti 2019] e está organizado em mais três seções. A Seção 2 apresenta o pseudocódigo do algoritmo e mais detalhes sobre ele, a Seção 3 estende uma revisão bibliográfica com foco em propostas de melhoramentos relacionados à aceleração do processo de execução do k -Means e a Seção 4 finaliza o artigo elencando algumas investigações realizadas.

2 | O ALGORITMO K-MEANS

O k -Means padrão foi proposto em 1957 em um documento interno à Bell Telephone Laboratories [Lloyd 1957]. O algoritmo foi publicado no artigo [MacQueen 1967] e, também, foi publicado em periódico por Lloyd em 1982 [Lloyd 1982].

Entre algumas situações que contribuem para o k -Means ter um processamento não muito rápido estão (a) número alto de instâncias a serem agrupadas; (b) número alto de cálculos de distâncias entre instâncias e centroides que o algoritmo deve realizar e (c) necessidade do algoritmo requerer muitas iterações para convergir. O pseudocódigo do k -Means na Figura 1 é baseado nas descrições do algoritmo encontradas em [Witten et al. 2011] e [Han et al. 2012]. O algoritmo espera como entrada (a) um conjunto com N instâncias de dados $I = \{I_1, I_2, \dots, I_N\}$, em que cada instância I_i , $1 \leq i \leq N$, é descrita por valores associados a M atributos A_j , $1 \leq j \leq M$, bem como (b) um valor para o parâmetro k , que representa o número de grupos que o agrupamento a ser induzido deve ter. O algoritmo produz um agrupamento representado por um conjunto de conjuntos que no pseudocódigo mostrado na Figura 1 é notado por $AG = \{G_1, G_2, \dots, G_k\}$.

Na fase de inicialização o k -Means padrão escolhe randomicamente k instâncias de I , e elege cada uma delas como centroide (representativo) para cada um dos k grupos.

O agrupamento ao final da fase de inicialização é representado por um conjunto com k elementos, em que cada elemento é um conjunto que tem por elemento apenas o centroide.

Na fase iterativa do algoritmo, indicada pelo comentário *% Indução do Agrupamento* AG, na Figura 1, cada uma das instâncias restantes de I é então atribuída ao grupo cujo respectivo centroide lhe seja mais próximo, por meio do cálculo da distância de cada instância a cada um dos k centroides; usualmente a distância euclidiana é usada. Na sequência, a média dos valores de atributos que representam as instâncias que participam de cada um dos k grupos é calculada e os k centroides são atualizados. O processo é então repetido com os novos centroides de grupos, até que atinja estabilidade, caracterizada como a situação em que as mesmas instâncias são atribuídas aos grupos aos quais já pertencem em iterações consecutivas.

```
procedure k-Means( $I, k, AG$ )  
Input:  $I = \{I_1, I_2, \dots, I_N\}$  %conjunto com N instâncias de dados a serem agrupadas  
           $k$  % número de grupos a serem criados  
Output:  $AG = \{G_1, G_2, \dots, G_k\}$  %agrupamento formado por k grupos induzidos a partir de I  
begin  
% Inicialização  
% no passo (1) cada grupo é definido apenas pelo centroide  
(1) escolha arbitrária de k instâncias do conjunto I, como centroides dos grupos  
 $G_1, G_2, \dots, G_k$   
  
% Indução do agrupamento AG  
(2) repeat  
  (3) (re)atribuir cada instância  $I_i$  e  $I$  ( $i=1, \dots, N$ ) ao grupo cujo centroide que lhe seja mais próximo;  
  (4) atualizar os centroides de cada grupo, como a média dos valores das suas instâncias  
(5) until nenhuma alteração aconteça.  
end.  
return  $AG = \{G_1, G_2, \dots, G_k\}$   
end_procedure
```

Figura 1. Pseudocódigo do k-Means [Witten *et al.* 2011] e [Han *et al.* 2012].

A Figura 2 ilustra duas execuções do k-Means, identificadas na figura por (1a) (1b) e por (2a) (2b), utilizando um conjunto com 40 instâncias de dados bidimensionais e o valor de k estabelecido como 3. Em cada uma das execuções, entretanto, a inicialização do conjunto de centroides é feita randomicamente e as figuras (1b) e (2b) exibem como as diferentes inicializações de centroides (exibidas em (1a) e (2a) respectivamente) influenciam o agrupamento final induzido.

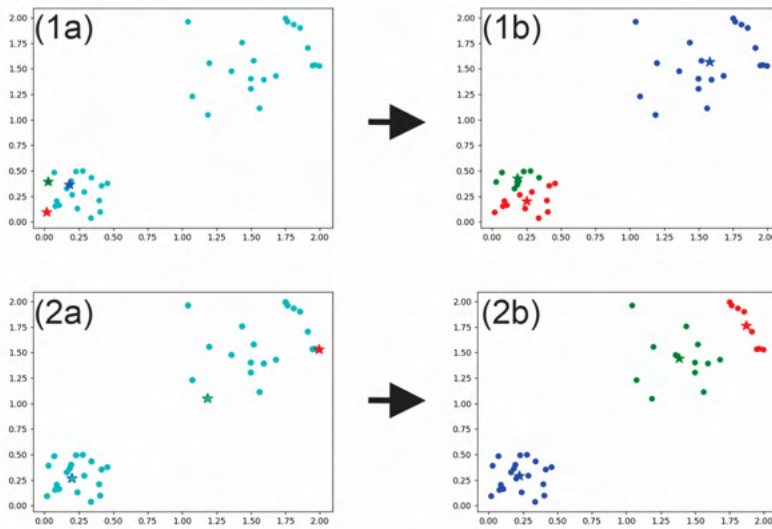


Figura 2. Impacto da fase de inicialização no agrupamento final induzido com a representação de duas execuções do algoritmo k-Means, para $k=3$, indicadas por (1) e (2). Na execução (1), (1a) é fase de inicialização dos centroides e (1b) o agrupamento final obtido. Na execução (2) a mesma notação é utilizada. Os três caracteres estrela representam cada um dos três centroides de grupos.

Na versão padrão do algoritmo k-Means em [Lloyd 1982] a escolha dos k centroides iniciais na fase de inicialização é feita aleatoriamente entre as N instâncias pertencentes ao conjunto C . Tal escolha aleatória dos centroides iniciais no algoritmo k-Means pode acarretar alguns inconvenientes, tais como: (1) a cada execução do algoritmo k-Means o agrupamento induzido não necessariamente será o mesmo, ainda que utilizando o mesmo conjunto de instâncias e o mesmo valor para k ; (2) pode ocorrer a escolha de instância com valor extremo como centroide inicial, acarretando distorções no agrupamento induzido, não representando adequadamente os grupos naturais do conjunto; (3) duas instâncias muito próximas podem ser escolhidas como centroides iniciais, levando o agrupamento a uma solução local que também não representa adequadamente os grupos naturais do conjunto de instâncias; entre outros. Portanto a escolha dos centroides iniciais é uma fase relevante do algoritmo k-Means principalmente por tal escolha interferir na indução do agrupamento final, como mostrado na Figura 2. Na literatura podem ser encontradas várias propostas que buscam resolver o problema da inicialização dos centroides de grupos bem como de estudos que fazem revisões de algumas dessas propostas, tais como as apresentadas em [Al-Daoud & Roberts 1996] [Khan & Ahmad 2004] [Celebi et al. 2013] [Maedeh & Suresh 2013] [Nicoletti & Oliveira 2020].

3 | PROPOSTAS DE ACELERAÇÃO DO K-MEANS

Muitos pesquisadores têm investido no desenvolvimento de estratégias com vistas à aceleração do processamento realizado por algoritmos de agrupamento em geral. O foco dessa seção é a apresentação de uma revisão bibliográfica conduzida com o objetivo de identificar estratégias e algoritmos encontrados na literatura que foram propostos com o objetivo exclusivo de acelerar o processamento do k-Means e que podem ser caracterizados como melhoramentos algorítmicos.

Hamerly em [Hamerly 2010] comenta que quando as instâncias de dados a serem agrupadas têm alta dimensionalidade, esquemas de indexação, como aquele implementado por árvores k-d, não funcionam bem, a ponto do processo do exame de cada instância (i.e., sem o uso de uma estrutura que favoreça a aceleração) ser bem mais rápido do que processos realizados por algoritmos que implementam aceleração para baixa dimensionalidade. Os autores informam em [Hamerly & Drake 2015] que para conjuntos de instâncias de dados descritas por um número pequeno de atributos (i.e., com baixa dimensionalidade horizontal), a indexação das instâncias a serem agrupadas é uma maneira efetiva de acelerar o k-Means. Apesar dos trabalhos descritos em [Kanungo et al. 2002] e [Pelleg & Moore 1999] terem sido feitos por pessoas distintas, em épocas distintas, ambos são similares na maneira como propõem a adaptação de uma árvore k-d padrão com o propósito de promover uma aceleração do k-Means.

Outro aspecto importante a ser considerado quando do uso de algoritmos que usam árvores k-d como estrutura para armazenamento das instâncias e de informações complementares, diz respeito aos custos envolvidos na construção e uso de tal estrutura. Para um conjunto com N instâncias de dado o custo da construção de uma árvore k-d é da ordem de $O(N \log(N))$ o que aproximadamente duplica o custo de memória necessária. Também, se o conjunto de instâncias sofre mudanças, a atualização da árvore k-d para refletir essas mudanças não é um processo trivial com baixo custo computacional. Como evidenciado nos experimentos descritos em [Pelleg & Moore 2000], o algoritmo conhecido como Algoritmo Blacklisting é efetivo para a indução de agrupamentos em conjuntos com um número elevado de instâncias (dimensionalidade vertical alta). Os autores também comentam que o algoritmo se torna lento quando a dimensionalidade horizontal das instâncias a serem agrupadas se torna maior do que 8. Em conjuntos de instâncias com alta dimensionalidade, as instâncias e centroides tendem a ficar longe uns dos outros e a possibilidade de uso de procedimentos de poda acaba sendo reduzida.

Em [Moore 2000] o autor descreve uma proposta de estrutura hierárquica identificada como a hierarquia de âncoras, adequada para lidar com instâncias de dados com alta dimensionalidade, que satisfaz a desigualdade triangular. Similarmente ao uso de árvores k-d, a construção e a manutenção dessa estrutura hierárquica podem ser complexas e demandam um investimento computacional alto, tanto em tempo quanto em memória.

Alguns trabalhos na área ao invés de lidar diretamente com agrupamentos em conjuntos de instâncias com alta dimensionalidade, lidam com uma projeção desses conjuntos em um espaço com baixa dimensionalidade e, na sequência, usam algoritmos adequados para induzir agrupamentos de instâncias com baixa dimensionalidade. O método para redução de dimensionalidade conhecido como Principal Component Analysis é abordado em associação ao aprendizado não supervisionado realizado pelo k-Means, no trabalho descrito em [Ding & He 2004]. Os resultados obtidos nos experimentos realizados indicam que os processos de redução de dimensionalidade não supervisionada e de aprendizado não supervisionado estão fortemente relacionados.

Considerando que o efeito de uma inicialização adequada dos centroides promove a indução mais rápida de um agrupamento, métodos de inicialização de centroides podem, de certa forma, ser abordados como algoritmos de aceleração do k-Means. Em uma situação em que o número de grupos do agrupamento a ser induzido é k , na fase de inicialização do k-Means padrão (Figura 1), k instâncias, randomicamente escolhidas, constituem o conjunto inicial dos k centroides. Se, ao invés de uma escolha randômica, um algoritmo for utilizado para uma escolha apropriada dos centroides iniciais, a indução do agrupamento final pode eventualmente ser acelerada. Esse é o caso do algoritmo Furthest-First [Hochbaum & Shmoys 1985], como o algoritmo a ser empregado na fase de inicialização do k-Means. O Furthest-First começa escolhendo randomicamente uma instância como o primeiro centroide e, então, repetidamente seleciona, como o próximo centroide, a instância que está mais longe de qualquer centroide já escolhido. Tal algoritmo, entretanto, apesar de fácil e de ser rapidamente implementado, tem a tendência de escolher *outliers*, como parte do conjunto inicial de centroides, dada a tendência de *outliers* estarem situados próximos à fronteira da massa de dados considerados.

Bradley e Fayyad em [Bradley & Fayyad 1998] apresentam um procedimento para calcular um refinamento do processo de inicialização de centroides, que permite que o algoritmo iterativo convirja para um melhor mínimo local. O procedimento em questão pode ser usado agregado a um grande número algoritmos de agrupamento, tanto para dados discretos quanto contínuos. Os resultados obtidos e discutidos no trabalho evidenciam que o conjunto inicial de centroides, quando refinado pelo procedimento proposto e usado com o k-Means, provoca um melhoramento nos resultados do k-Means. Um estudo empírico sobre a contribuição de estratégias de inicialização do k-Means com vistas à diminuição do número de iterações do algoritmo está apresentada em [Nicoletti & Oliveira 2020].

A referência [Phillips 2002] descreve duas estratégias relativamente simples para acelerar o processamento do algoritmo k-Means. O uso de tais estratégias não modifica o resultado obtido pelo algoritmo ou seja, o k-Means com ou sem o uso de qualquer das duas estratégias, usando entretanto os mesmos centroides iniciais, sempre induz o mesmo agrupamento. Como comentado em [Elkan 2003], o uso da propriedade conhecida como desigualdade triangular quando da implementação do k-Means padrão é o de acelerar o

tempo de processamento do algoritmo. O emprego da desigualdade triangular permite que muitos dos cálculos realizados pelo k-Means padrão, possam ser evitados, o que acelera o processo de indução executado pelo algoritmo. A proposta nomeada neste texto como k-Means-Elkan, contempla o uso da propriedade de duas maneiras distintas, subsidiadas por dois resultados teóricos, bem como de um monitoramento dos limites superiores e inferiores das distâncias entre instâncias e centroides de grupos.

O algoritmo proposto por Hamerly em [Hamerly 2010] é considerado por seu autor como uma simplificação e modificação do k-Means-Elkan. Assim como o k-Means-Elkan, o k-Means-Hamerly usa limites para as distâncias, que são eficientemente atualizados, bem como usa a desigualdade triangular para evitar cálculos de distâncias entre instâncias e centroides. O k-Means-Hamerly emprega dois limites de distância, por instância de dados, para seus dois centroides mais próximos. Um deles é um limite superior na distância da instância ao seu centroide mais próximo e o outro é um limite inferior na distância ao segundo centroide mais próximo. Com base nos resultados obtidos dos experimentos descritos em [Hamerly 2010], o autor comenta que o k-Means-Hamerly teve melhor desempenho em conjuntos de dados com dimensionalidade pequena e moderada, enquanto que o k-Means-Elkan teve melhor desempenho em dados com alta dimensionalidade. De certa maneira esses dois algoritmos podem ser abordados como complementares um do outro, sendo a escolha de um deles sempre dependente da dimensionalidade das instâncias de dados a serem agrupadas.

O algoritmo Yinyang [Ding et al. 2015] também usa a desigualdade triangular para acelerar o algoritmo k-Means, de maneira similar àquela utilizada no algoritmo proposto por Elkan. No Yinyang os limites superiores e inferiores são utilizados como filtros para detectar cálculos de distância desnecessários, o que acelera as etapas de atribuição e de atualização dos centroides. De acordo com os autores o uso desses filtros gera um considerável ganho de performance, superando consistentemente a performance do k-Means, permitindo ser até 3 vezes mais rápido que as principais otimizações conhecidas.

O algoritmo Fission-Fusion proposto por Yu e Dai em [Yu & Dai 2017] como uma aceleração do k-Means, faz uso de dois filtros para evitar realizar cálculos de distâncias entre instâncias e centroides e, assim como as estratégias propostas por Elkan e por Ding e coautores, o Fission-Fusion faz uso de limites superiores e limites inferiores. Inicialmente o Fission-Fusion executa uma iteração completa criando um agrupamento inicial e, durante tal iteração, gera os limites superiores e inferiores dos grupos do agrupamento induzido. A partir da segunda iteração o Fission-Fusion utiliza filtros de grupos de instâncias. Como resultado da filtragem os centroides que satisfazem a condição do filtro são descartados por não satisfazerem a condição de serem centroides mais próximos da instância. A partir da terceira iteração os subgrupos pertencentes aos grupos de instâncias são verificados no filtro de subgrupos, pois os subgrupos possuem limites superiores e limites inferiores mais restritos o que promove uma filtragem mais eficaz. Somente é calculada a distância

entre instâncias pertencentes aos subgrupos e os centroides que não foram descartados por esses dois filtros (grupos e subgrupos).

4 | CONSIDERAÇÕES FINAIS

Este artigo apresentou uma extensão da revisão bibliográfica de algoritmos/estratégias encontrados na literatura técnica, com foco no algoritmo k-Means, que têm como objetivo acelerar a execução do algoritmo na indução do agrupamento final [Matte & Nicoletti 2019]. O levantamento feito não foi exaustivo; buscou-se, entretanto, identificar as propostas mais relevantes com o intuito de providenciar um contexto e identificar as mais promissoras para uma investigação mais detalhada. Os trabalhos apresentados em [Matte 2020] e [Matte & Nicoletti 2022] descrevem alguns dos algoritmos discutidos anteriormente e apresentam experimentos e resultados de vários algoritmos em domínios de dados diversos.

REFERÊNCIAS

[Al-Daoud & Roberts 1996] Al-Daoud M, Roberts SA (1996) New methods for the initialization of clusters, *Pattern Recognition Letters*, v. 17, pp. 451-455.

[Bradley & Fayyad 1998] Bradley PS, Fayyad U (1998) Refining initial points for k-means clustering, in: Proc. of the 15th International Conference on Machine Learning, pp. 91-99.

[Celebi et al. 2013] Celebi, ME, Kingravi HA, Vela PA (2013) A comparative study of efficient initialization methods for the k-means clustering algorithm, *Expert Systems with Applications*, v. 40, pp. 200-120.

[Chapelle et al. 2006] Chapelle O, Scholkopf B, Zien A (2006) *Semi-supervised Learning*, MIT Press.

[Ding & He 2004] Ding C, He X (2004) K-means clustering via principal component analysis, In: Proc. of the 21st Int. Conference on Machine Learning, Banff, Canada, pp.255-232.

[Ding et al. 2015] Ding Y, Zhao Y, Shen X, Musuvathi M, Mytkowicz T (2015) Yinyang k-means: A drop-in replacement of the classic k-means with consistent speedup, In: Proc. of the Int. Conference on Machine Learning, pp. 579-587.

[Elkan 2003] Elkan C (2003) Using the triangle inequality to accelerate k-Means, In: Proc. of the Twentieth International Conference on Machine Learning (ICML-2003), pp. 147-153.

[Hamerly 2010] Hamerly G (2010) Making k-Means even faster, In: Proc. of the SIAM International Conference on Data Mining, pp. 130-140.

[Hamerly & Drake 2015] Hamerly G, Drake J (2015) Accelerating Lloyd's algorithm for k-Means clustering, in: *Partitional Clustering Algorithms*, Springer-Verlag, pp. 41-78. doi:10.1007/978-3-319-09259-1_2.

[Han et al. 2012] Han J, Kamber M, Pei J (2012) *Data Mining Concepts and Techniques*, 3rd. Ed., Amsterdam: Morgan Kaufmann Publishers.

[Hochbaum & Shmoys 1985] Hochbaum DS, Shmoys DB (1985) A best possible heuristics for the k-center problem, *Mathematics of Operations Res.*, v. 10, no. 2, pp. 180-184.

[Kanungo *et al.* 2002] Kanungo T, Mount DM, Netanyahu NS, Piatko CD, Silveman R, Wu AY (2002) An efficient k-Means clustering algorithm: analysis and implementation, *IEEE Transactions on Pattern Analysis and Machine Intel.*, v. 24, no. 7, pp. 881-892.

[Khan & Ahmad 2004] Khan SS, Ahmad A (2004) Cluster center initialization algorithm for k-Means clustering, *Pattern Recognition Letters*, v. 25, pp. 1293-1302.

[Lloyd 1957] Lloyd SP (1957) Least square quantization in PCM, *Bell Telephone Laboratories Paper*.

[Lloyd 1982] Lloyd SP (1982), Least squares quantization in PCM, *IEEE Transactions on Information Theory*, v. 28, no. 2, pp. 129-137.

[Maedeh & Suresh 2013] Maedeh A, Suresh K (2013) Design of efficient k-Means clustering algorithm with improved initial centroids, *International Journal of Engineering and Technology*, v. 5, no. 1, pp. 33-38.

[Matte & Nicoletti 2019] Matte MK, Nicoletti MC (2019) Revisão de estratégias para a aceleração do algoritmo k-Means, *Anais do XV WCF (Workshop em Computação da FACCAMP)*, v. 6, pp. 1-6.

[Matte 2020] Matte, MK (2020) Impacto do uso da desigualdade triangular para acelerar o algoritmo k-Means, *Dissertação de Mestrado, UNIFACCAMP, C. L. Paulista*.

[Matte & Nicoletti 2022] Matte, MK, Nicoletti MC (2022) An empirical evaluation of strategies based on the triangle inequality for accelerating the k-Means algorithms, *in press (forthcoming article)*, *International Journal of Innovative Computing and Applications*, Inderscience Publishers.

[MacQueen 1967] MacQueen JB (1967). Some methods for classification and analysis of multivariate observations, In: *Proc. of The 5th Berkeley Symposium on Mathematical Statistics and Probability*, University of California Press, v. 1, pp. 281-297.

[Moore 2000] Moore AW (2000) The anchors hierarchy: using the triangle inequality to survive high dimensional data, In: *Proc. of The Sixteenth Conference on Uncertainty in Artificial Intelligence (UAI'00)*, pp. 397-405.

[Nicoletti & Oliveira 2020] Nicoletti MC, Oliveira AF (2020) Empirical evaluation of five algorithms for the initialization phase of the k-Means algorithm, *International Journal of Hybrid Intelligent Systems*, IOS Press, v. 16, no. 1, pp. 35-53.

[Pelleg & Moore 1999] Pelleg D, Moore A (1999) Accelerating exact k-Means algorithms with geometric reasoning, In: *Proc. of The Fifth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 277-281.

[Pelleg & Moore 2000] Pelleg D, Moore A (2000) X-means: extending K-means with efficient estimation of the number of clusters, In: *Proceedings of the 17th International Conf. on Machine Learning*, pp. 727-734.

[Phillips 2002] Phillips SJ (2002) Acceleration of K-Means and related clustering algorithms, In: Mount D. M., Stein C. (eds) *Algorithm Engineering and Experiments (ALENEX 2002)*, *Lecture Notes in Computer Science*, v. 2409, Berlin:Springer-Verlag, pp 166-177.

[Theodoridis & Koutroumbas 2009] Theodoridis S, Koutroumbas K (2009) *Pattern Recognition*, 4th Ed., USA: Elsevier.

[Witten et al. 2011] Witten IH, Frank E, Hall MA (2011) *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd. Ed., Amsterdam: Morgan Kaufmann Publishers.

[Yu & Dai 2017] Yu Q, Dai BR (2017) Accelerating k-Means by grouping points automatically, In: Proc. of the Int. Conference on Big Data Analytics and Knowledge Discovery, Springer, Cham, pp. 199-213.

[Witten et al. 2011] Witten IH, Frank E, Hall MA (2011) *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd. Ed., Amsterdam: Morgan Kaufmann Publishers.

ÍNDICE REMISSIVO

A

Acetilcolinesterase 128, 130, 131, 132, 134, 137

Agrupamentos 18, 19, 23, 24

Ahorro 110, 111, 112, 113, 114, 116, 118, 119

Aprendizado de máquina 18

Aproveitamento de resíduos sólidos 63

Atividade antifúngica 127, 132

B

BNCC 1, 2, 3, 4, 5, 81

C

Cobertura vegetal 29, 150

Covid-19 1, 2, 3, 84, 85, 139, 146, 147, 148, 177

Criptocarste 29, 30, 33, 34, 35, 37, 38, 39, 41

D

Desafios tecnológicos 84

Desempenho acadêmico 208, 210, 211, 212

Desenvolvimento humano 73, 74, 80, 82

Design thinking 55, 56, 57, 58, 60, 61, 90

Desigualdade triangular 18, 23, 24, 25, 27

E

Educação matemática 74

Engenharia de software 56, 57, 60

ENOS 42, 44, 48

Ensino de engenharia 107

Ensino de física 1, 2, 4, 88, 90, 98, 109

Ensino remoto 1, 2, 3, 4, 5, 84, 177, 188

Epicarste 29, 30, 31, 32, 33, 35, 38, 39

Estudantes universitarios 208

F

Ferramentas tecnológicos 177, 188

Física 1, 2, 3, 4, 5, 84, 85, 86, 87, 88, 89, 90, 91, 98, 101, 102, 105, 106, 108, 109, 150, 164, 168, 177, 185, 187, 188, 192, 199

Física experimental V 177, 188

G

Geoconservação 139, 144, 149

Geologia 139, 141, 143, 146, 149

Geoparque 139, 140, 141, 144, 145, 146, 147, 148, 149

Geossítios 139, 142, 143, 144, 149

Gestión social 110

I

Inovação 55, 56, 61, 89, 108

Inovação das ideias 55

J

Jogo matix 74

K

K-means 18, 26, 27

L

Leite 120, 121, 122, 124, 126

Liofilização 120, 121, 122, 123, 126

M

Magnetostática 177, 178, 179, 180, 187

Matemáticas 208, 209, 210, 211, 212

Material de referência 120, 121, 126

Mudanças climáticas 42, 44, 53

N

Números inteiros 73, 74, 75, 77, 78, 81, 82

P

Pesquisa 19, 20, 44, 71, 74, 75, 83, 86, 88, 89, 90, 105, 107, 109, 131, 132, 180, 182, 200

Pobreza energética 110, 111, 112, 114, 115, 116, 117, 118, 119

Potencial antioxidante 128, 132

Processos geoquímicos 29, 30, 31, 34

S

Sincorá 139, 140, 141, 142, 143, 144, 145, 146, 147, 148, 149

Solos 29, 36, 37, 38, 64, 71

Superfície urbana 150

Sustentabilidade 63

T

Temperatura por satélite 150


Tintas naturais 63, 64, 65, 71

U

Urbanização 42, 46, 150, 160

CIÊNCIAS EXATAS e da terra:

Observação, formulação e previsão 2



www.atenaeditora.com.br 


contato@atenaeditora.com.br 

@atenaeditora 

www.facebook.com/atenaeditora.com.br 

CIÊNCIAS EXATAS e da terra:

Observação, formulação e previsão 2



www.atenaeditora.com.br

contato@atenaeditora.com.br

@atenaeditora

www.facebook.com/atenaeditora.com.br