



Notas Técnicas

CBPF-NT-002/25

março 2025

A influência da Redução de Brilho e presença de Ruído em modelos de predição de classes de Dunham: Eficácia do tratamento e efeitos em cada classe.

Rayan T.C.M. Barbosa, Elisangela L. Faria, Rômulo R. Oliveira, Clécio R. Bom,
Paulo Russano P. J., Márcio P. de Albuquerque, Marcelo P. de Albuquerque

A influência da Redução de Brilho e presença de Ruído em modelos de predição de classes de Dunham: Eficácia do tratamento e efeitos em cada classe.

The Influence of Brightness Reduction and Noise Presence in Dunham Class Prediction Models: Treatment Effectiveness and Effects on Each Class.

Rayan T. C. M. Barbosa, Elisangela L. Faria, Rômulo R. Oliveira, Clécio R. Bom,
Paulo Russano P. J., Márcio P. de Albuquerque, Marcelo P. de Albuquerque*

Centro Brasileiro de Pesquisas Físicas

Submetido em 26/10/2023 Aceito: 14/03/2025

Resumo: Um conjunto de imagens de alta qualidade é fundamental para garantir a precisão e confiabilidade das tarefas de classificação de imagens, pois permite que os algoritmos de aprendizado de máquina se concentrem nos padrões e características relevantes, evitando interferências de possíveis ruídos que possam comprometer os resultados da tarefa de classificação. Neste estudo, investigamos os impactos dos erros aleatórios de aquisição e iluminação nas classes de rochas sedimentares carbonáticas, utilizando redes neurais para classificação Dunham. Com um conjunto de dados contendo 684 imagens de quatro classes (Wackstone, Packstone, Grainstone e Mudstone), analisamos a relação entre de redução de brilho e/ou presença de ruído *Salt-And-Pepper* e seu impacto nas classes. Observamos que classes mais homogêneas sofreram menos com as alterações, enquanto a classe Packstone apresentou resultados menos satisfatórios. Além disso, testamos a recuperação de desempenho usando equalização de brilho e filtros de ruído, sendo o filtro de desfoque mediano se apresentando mais eficaz que a equalização de brilho. As classes apresentaram comportamentos diferentes em relação ao tipo erro inserido e a combinação deles intensificou o impacto negativo nas classes mais heterogêneas. Essas conclusões fornecem insights relevantes para o desenvolvimento de modelos de classificação de rochas sedimentares carbonáticas.

Palavras chave: Aprendizado de máquina, Geologia, Redução de Ruído, Visão Computacional, Transferência de Aprendizado.

Abstract: A set of high-quality images is crucial to ensure the accuracy and reliability of image classification tasks. This quality allows machine learning algorithms to focus on relevant patterns and features, preventing potential noise interference that could compromise classification results. In this study, we investigated the impacts of random acquisition and lighting errors on classes of carbonate sedimentary rocks using neural networks for Dunham classification. With a dataset comprising 684 images across four classes (Wackstone, Packstone, Grainstone, and Mudstone), we analyzed the relationship between brightness reduction and salt and pepper noise presence and their impact on the classes.

We observed that more homogeneous classes were less affected by these changes, while the Packstone class yielded less satisfactory results. Additionally, we tested performance recovery using brightness equalization and noise filters, with the median blur filter proving more effective than brightness equalization. The classes exhibited different behaviors concerning the type of error introduced, and their combination exacerbated the negative impact on the more heterogeneous classes. These findings offer valuable insights for the development of models for carbonate sedimentary rock classification.

Keywords: Machine Learning, Geology, Image de-noising, Transfer Learning, Computer vision.

1. INTRODUÇÃO

A classificação de lâminas petrográficas por meio de redes neurais tem sido amplamente explorada em diversos centros de pesquisa devido à dificuldade inerente à classificação manual. Esta complexidade resulta da grande quantidade de dados envolvidos, frequentemente levando a fatores subjetivos que prejudicam a eficácia da classificação [1]. Atualmente, há um esforço para desenvolver modelos ou processos que proporcionem alta precisão, no entanto, a falta de qualidade dos dados e o número reduzido de dados rotulados comprometem significativamente esse processo [2]. Além da complexidade do problema, existem desafios na seleção, coleta e obtenção de imagens digitais das amostras. Essas etapas são frequentemente realizadas manualmente, muitas das vezes sem um padrão ou controle adequado, o que resulta em imagens com variações significativas de luminosidade, tonalidade, cor e outros efeitos indesejados que complicam o processo de classificação de imagens [3].

Com o propósito de superar esses desafios, técnicas de pré-processamento têm sido desenvolvidas e amplamente discutidas na literatura. Entretanto, em cenários de maior complexidade, especialmente em tarefas relacionadas à visão computacional e dados geológicos, os resultados obtidos até o momento são modestos e carecem de uma investigação mais profunda.

Ao abordar a classificação litológica de lâminas finas de rochas carbonáticas, diversos tipos de erros podem ser identificados. Esses erros incluem principalmente ruídos aleatórios e de iluminação [4].

Dentro deste contexto, este trabalho tem como objetivo analisar os seguintes tópicos:

1) Há correlação entre a presença dos erros de aquisição aleatórios e de iluminação, assim como o seu impacto nas diferentes classes de rochas sedimentares carbonáticas dentro da classificação Dunham?

2) A aplicação de equalização de brilho e filtros de redução de ruído conseguem recuperar a perda de desempenho causada pela introdução de ruído de aquisição e redução de brilho?

3) As classes se comportam de forma diferente em relação aos ruídos aplicados e seus respectivos tratamentos?

Dentro deste contexto, este trabalho visa a classificação de imagens de lâminas carbonáticas através de redes neurais convolucionais com uma etapa voltada para o pré-processamento de imagens de forma a responder aos questionamentos citados anteriormente.

2. BASE DE DADOS

O conjunto de dados utilizados neste trabalho possui um total de 684 fragmentos de imagens RGB salvas em formato TIFF com dimensão regular de 200x200 pixels e divididas em quatro classes: Wackestone, Packstone, Grainstone

e Mudstone. A quantidade de imagens para cada classe estudada pode ser visualizada na Tabela I e na Fig. 1 podem ser visualizados exemplos das imagens referentes as 4 litologias analisadas.

Tabela I. Proporção de cada litologia analisada

Classe Dunham	Número de Amostras
Grainstone	228
Packstone	48
Wackestone	180
Mudstone	228
Total	684




Figura 1. Visualização das imagens pertencentes as quatro classes contidas na base de dados em seu formato original. Sendo a) Grainstone; b) Mudstone; c) Packstone; d) Wackestone.

3. PRÉ-PROCESSAMENTO DAS IMAGENS

A imagem é o elemento principal da visão computacional, por isso a qualidade da mesma é indispensável para um bom resultado nas mais diversas aplicações de visão computacional [13]. Com o objetivo de compreender esta relação, foram aplicados diferentes fluxos de pré-processamento, emulando cenários de redução de brilho e aplicação ruído nos inputs iniciais.

Para a aproximação destes cenários, foram empregadas diferentes ferramentas e técnicas. Inicialmente, para reduzir o brilho, foi aplicada a função *Subtract*. Esta função realiza uma operação de subtração elemento a elemento entre dois *arrays*. Neste caso em específico um dos *arrays* é substituído pelas intensidades de cores das imagens, representada pelos valores de seus pixels que podem variar de 0 a 255, enquanto o segundo é constituído por uma constante de redução. Com o objetivo de alcançar um entendimento abrangente acerca dos efeitos causados pela redução de brilho, a constante de

redução assumiu três valores de intensidades distintas sendo eles -50, -100 e -150. Em operações com imagem os valores são limitados a um intervalo específico, no caso de uma imagem RGB de 8bits os valores dos pixels são limitados entre 0 e 255. Caso uma função venha a subtrair pixels onde o resultado desta operação ocorra em pixels negativos, este valor é desconsiderado e truncado para zero. A mesma coisa ocorreria em caso de uma operação de adição. Dependendo do formato da imagem, estes valores podem até se tornarem negativos durante etapas intermediárias do processamento de imagem, porém ao fim do processo, sendo uma exibição ou salvamento, os valores são normalizados para um intervalo válido.

Em um passo seguinte o efeito de *Salt-And-Pepper* foi utilizado para inserir ruídos nas imagens. Este tipo de ruído é baseado em uma probabilidade escolhida que aplica pontos brancos e pretos isolados, reproduzindo de forma sintética erros na aquisição ou na transmissão dos dados. Ao aplicar o ruído *Salt-And-Pepper* o pixel recebe uma porcentagem referente a probabilidade dele ser substituído por um valor muito alto (branco) ou muito baixo (preto). Esta porcentagem pode ser fixa como 5% (0.05) ou intervalar (ex: entre 5% e 10%). Da mesma forma que na etapa anterior, foram aplicadas diversas intensidades deste ruído, buscando analisar a sua influência sobre a tarefa de classificação, de acordo com sua intensidade. Para isso, foram definidos três valores de probabilidade (0.15, 0.30 e 0.45) e adicionados às imagens de forma isolada e somada a redução de brilho.

Com base nessas etapas, foram construídos inicialmente 16 conjuntos de imagens. O fator de redução de brilho e a probabilidade de ruído *Salt-And-Pepper* de cada grupo pode ser verificada na Tabela III. Esses conjuntos foram duplicados, e em seguida, processados usando técnicas específicas de tratamento de acordo com o tipo de ruído presente na imagem. Dessa forma foi possível obter um total de 32 conjuntos de imagens, sendo 16 conjuntos não tratados e 16 tratados.

Tabela II. Grupos de imagens de Treinamento e Validação*

(0, 0)	(0, 0.15)	(0, 0.30)	(0, 0.45)
(-50, 0)	(-50, 0.15)	(-50, 0.30)	(-50, 0.45)
(-100, 0)	(-100, 0.15)	(-100, 0.30)	(-100, 0.45)
(-150, 0)	(-150, 0.15)	(-150, 0.30)	(-150, 0.45)

* Cada grupo é representado no formato (x, y) onde x é o seu fator de redução de brilho e y a probabilidade de inserção de ruído *Salt-And-Pepper*.

Com o objetivo de restaurar de maneira equilibrada e uniforme a luminosidade de conjuntos de imagens que tenham sofrido redução de brilho, empregou-se uma técnica de equalização de brilho baseada no histograma do canal. Essa técnica visa aprimorar o contraste em uma imagem, expandindo a gama de intensidades dos pixels no histograma, a fim de obter uma distribuição mais uniforme ao longo das intensidades disponíveis na imagem. O principal resultado almejado por esse método é uma imagem com maior clareza e detalhes mais evidentes. Entretanto, é fundamental notar




Figura 2. Representação dos resultados obtidos, de cada uma das classes ao ser inserido ruído e redução de brilho, de forma isolada, combinada, tratada e não tratada. A primeira linha representa as imagens alteradas e a segunda após receber o tratamento. Foi escolhido um valor médio de ruído (0.3) e redução de brilho (-100), dentre os utilizados, para melhor visualização.

que a equalização do histograma pode não ser apropriada para todas as imagens e pode resultar em efeitos indesejados em determinadas situações. Portanto, é sempre aconselhável avaliar os efeitos da equalização do histograma em um contexto específico antes de aplicá-la indiscriminadamente a todas as imagens.

Concomitantemente, o canal escolhido para a equalização está diretamente relacionado ao resultado obtido. Isso ocorre porque cada canal é construído com base nas características

da imagem. A redução de brilho nos canais RGB requer ajustes individuais em cada um dos 3 canais o que pode resultar em mudanças de cor e saturação, podendo assim prejudicar o processo de identificação e classificação de imagens. Neste trabalho, optou-se por utilizar o canal L do espaço de cores LAB. Em comparação com o espaço de cores RGB, o espaço LAB é um sistema de cores independente de dispositivo. O canal L representa exclusivamente a luminosidade do pixel, ou seja, variações na iluminação não afetam os outros canais A e B, que controlam as gamas de vermelho a verde e amarelo a azul, respectivamente. Portanto, ao mapear a imagem para o espaço de cores LAB, é possível corrigir o brilho de forma independente[14].

Os conjuntos em que foram aplicados ruído de *Salt-And-Pepper* foram tratados através de um filtro desfoque mediano com uma matriz de janela 3x3. Ao ser aplicado, cada pixel na imagem é substituído pela mediana dos pixels vizinhos em uma determinada janela. Esta técnica apresenta eficácia em reduzir o ruído de granulação em uma imagem, como o ruído *Salt-And-Pepper*. Diferentemente de outros filtros de suavização, como o desfoque gaussiano, o desfoque mediano preserva melhor as bordas e os detalhes da imagem, enquanto suaviza o ruído indesejado.

Nos casos em que houve combinação das duas alterações, o tratamento também foi combinado sendo primeiro tratado a redução de brilho seguida do ruído granulado. A ordem das técnicas foi escolhida com base na otimização do processo de tratamento e recuperação das imagens, a melhora do contraste e visibilidade proveniente da equalização do histograma do canal L evidencia os pontos gerados pelo ruído *Salt-And-Pepper* consequentemente facilitando o seu tratamento posterior com a aplicação do filtro mediano. A Fig. 2 apresenta exemplos ilustrativos dos resultados obtidos após o tratamento dos dados.

Essas técnicas foram aplicadas visando melhorar a qualidade e a diversidade do conjunto de dados, a fim de aprimorar o desempenho e a robustez dos modelos de análise e processamento de imagens.

Dado o número limitado de amostras disponíveis, cada um desses conjuntos foi introduzido separadamente no modelo de treinamento após passar por ampliações de dados, tais como translação, espelhamento, rotação e ajustes de contraste. Por fim, as imagens são sempre inseridas na rede no canal RGB.

4. MODELO E TREINAMENTO

As arquiteturas utilizadas neste estudo foram construídas através de técnicas de transferência de aprendizado. Essa metodologia envolve o treinamento de um modelo cujos parâmetros já foram previamente otimizados em outros conjuntos de dados. Este tipo de abordagem se destaca não apenas devido a sua economia de tempo computacional, mas também a possibilidade de conduzir a resultados refinados. Entretanto, algumas adaptações se fazem necessárias, como a inclusão de camadas ocultas adicionais com pesos inicializados de maneira distinta, especialmente quando as imagens ou objetos no modelo pré-treinado não guardam semelhanças significativas com as do modelo de destino.

No contexto das diversas arquiteturas de redes neurais convolucionais pré-treinadas disponíveis na literatura, optou-se por empregar a ResNet50 neste estudo. A escolha de se utilizar esta rede ocorre devido a sua arquitetura de grande profundidade (50, 100 ou mais camadas convolucionais), por ser amplamente adotada em aplicações de visão computacional. Sua principal função é atenuar a degradação do desempenho do modelo, que podem ocorrer em redes muito profundas, por meio de conexões residuais, e ela tem demonstrado um desempenho excepcional na resolução de desafios como classificação de imagens, detecção de objetos e segmentação semântica [1].

Tabela III. Arquitetura do modelo de treinamento*

Tipo de Camada	Formato de Saida	Parâmetros
InputLayer	(None, 200, 200, 3)	0
Cast to Float32	(None, 200, 200, 3)	0
RandomTranslation	(None, 200, 200, 3)	0
RandomFlip	(None, 200, 200, 3)	0
RandomRotation	(None, 200, 200, 3)	0
RandomContrast	(None, 200, 200, 3)	0
Resnet50	(None, 7, 7, 2048)	23,587,712
Flatten	(None, 100352)	0
Dense	(None, 4)	401,412
Softmax	(None, 4)	0

Total de parâmetros: 23,989,124

Treináveis: 401,412

Não treináveis: 23,587,712

A estrutura do modelo empregado (conforme ilustrado na Tabela III) inclui, em sua etapa inicial, camadas de entrada e aumento de dados, seguidas pela camada de leitura da ResNet50. A seleção dessas camadas iniciais tem como propósito tirar proveito da habilidade dessa rede preexistente de extrair características em níveis hierárquicos, visto que foi pré-treinada em extensos conjuntos de dados para a classificação de imagens.

A partir dessa configuração inicial, foi incorporada a camada de regularização (*flatten*) para converter a saída em um vetor unidimensional, preparando os dados para a subsequente camada densa de classificação. A camada *flatten* desempenha um papel crucial ao transformar o volume de características aprendidas pelas camadas convolucionais em um formato apropriado para a entrada na camada densa totalmente conectada que segue. Composta por 4 neurônios, essa camada utiliza uma ativação linear, focando na aprendizagem de padrões e informações específicas relacionadas à tarefa de classificação em questão. Considerando que o modelo precisa calcular um valor para cada uma das quatro classes treinadas, a escolha de quatro neurônios é adequada para atender aos requisitos particulares de nosso problema.

Por fim, conectamos a camada densa a uma camada de classificação *softmax* para normalizar os valores de saída em probabilidades, tornando mais claro o processo de escolha do nosso modelo e facilitando assim as análises que serão realizadas.

Os resultados obtidos indicam que o modelo treinado converge bem, apresentando uma acurácia de validação média

Tabela IV. Métricas de treinamento

Épocas	10
Batch Size	20
Otimizador	Adam
Função de Perda	Entropia Cruzada
Métrica	Entropia Cruzada Acurácia Categórica

de 0.94 e perda de validação média de 0.82 no treinamento do grupo 1 (com as imagens originais sem alterações). Na etapa de treinamento, foi aplicado pesos as classes devido ao seu desbalanceamento, para isso foram feitas ponderações baseadas na quantidade de imagens de cada classe sobre o total de imagens. As métricas utilizadas no treinamento estão apresentadas na Tabela IV.

5. AVALIAÇÃO

Em busca de trazer robustez a análise de desempenho da capacidade de generalização do modelo, optou-se por aplicar a técnica de validação cruzada k -fold com 5 pastas. Essa abordagem envolve a divisão dos dados disponíveis em k partições (ou *folds*) de tamanho aproximadamente igual, permitindo uma avaliação mais consistente e reduzindo a dependência de uma única divisão arbitrária dos dados em conjuntos de treinamento e teste. Essa escolha foi particularmente relevante considerando o tamanho limitado do conjunto de dados utilizado neste estudo, pois cada amostra teve a oportunidade de aparecer tanto no conjunto de treinamento quanto no conjunto de teste em uma determinada fase do treinamento, garantindo uma avaliação abrangente de todo o modelo [9].

A seleção dos aspectos a serem analisados no modelo se baseou em métricas e ferramentas que proporcionam uma avaliação completa e detalhada do desempenho do modelo de classificação. Essas métricas de avaliação foram minuciosamente examinadas em cada um dos 16 grupos, tanto nos grupos que receberam tratamento quanto nos que não receberam, dando especial atenção à matriz de confusão. Para garantir uma análise consistente, optou-se por utilizar a mesma divisão em *folds* em todos os grupos, permitindo assim uma avaliação que se baseasse no mesmo conjunto de dados de treinamento e teste.

Inicialmente, a acurácia e a *loss* foram avaliadas com o propósito de não apenas medir a capacidade do modelo em previsões de forma precisa em relação ao total de amostras, mas também calcular a diferença entre as previsões feitas pelo modelo e os valores reais dos dados de treinamento. Ambas as métricas combinadas fornecem uma visão geral da eficácia do modelo e de sua capacidade de aprendizagem a partir dos dados fornecidos durante o seu treinamento [10].

Para lidar com possíveis problemas de desbalanceamento de classes, foi adotada a ponderação do fator F1 (*F1-Weighted*). Essa métrica combina precisão (proporção de verdadeiros positivos em relação a todas as instâncias classificadas como positivas) e recall (proporção de verdadeiros positivos em relação a todas as instâncias que realmente pertencem à classe positiva), fornecendo uma visão equili-

brada do desempenho do modelo em situações em que algumas classes podem ter muito mais amostras do que outras (como ocorre em relação ao Packestone em nossa base de dados). Somado a isso, também se calculou a pontuação F1 por classe individualmente, visando investigar o desempenho do modelo em cada caso de forma isolada [11].

Finalmente, a matriz de confusão, também conhecida como tabela de contingência, foi utilizada como ferramenta para avaliar o desempenho do modelo de classificação. Essa tabela permite a visualização das previsões do modelo em comparação com os valores reais das classes, e sua análise contribui para compreender se as alterações feitas no dado causam alguma confusão entre as classes utilizadas neste estudo [12].

6. RESULTADOS

6.1. ACURÁCIA E LOSS DO MODELO

Os resultados da avaliação dos experimentos de classificação são apresentados nesta seção. Os gráficos a seguir ilustram a acurácia e *loss* do modelo em relação aos 32 experimentos realizados tanto no treinamento quanto na validação.

Inicialmente, ao analisarmos os valores de acurácia e *loss* do grupo de treinamento e validação, observa-se que há pouca diferença geral nos valores de acurácia entre os conjuntos tratados e não tratados (Fig. 3 e Fig. 4). Com exceção apenas nos casos em que apenas ruído *Salt-And-Pepper* foi inserido separadamente. Nesses casos as diferenças são significativamente maiores, chegando a quase 0.4 pontos entre os conjuntos com e sem tratamento, sugerindo uma eficácia significativa da filtragem na recuperação dos valores de acurácia. Esses valores aumentam de aproximadamente de 0.6 (grupo não tratado) para 0.9 (grupo tratado).

Essa tendência também pode ser observada no gráfico de *loss* (Fig. 4), onde a filtragem foi capaz de reduzir o valor de perda de 6 pontos para 1. No entanto, essa melhoria não foi constatada nos experimentos em que houve redução de brilho, tanto de forma isolada como combinada. Nesses casos, os conjuntos não filtrados apresentaram melhor desempenho, não sendo capazes de recuperar a acurácia nem reduzir a *loss*, exceto nos casos de redução mínima de brilho (onde o fator de redução é igual -50).

Esses resultados indicam que o filtro de desfoque mediano mostrou-se eficaz em facilitar o processo de classificação do modelo, aumentando a acurácia e reduzindo a *loss* na validação. Por outro lado, a equalização de brilho mostrou indícios de que sua aplicação em imagens mais escuras (-100 e -150) pode ter dificultado a tarefa de classificação dos modelos.

6.2. F1 – WEIGHT

Ao analisarmos os resultados da pontuação F1-score ponderada apresentados pela Fig. 5, podemos reafirmar o impacto do ruído *Salt-And-Pepper* e a eficácia do filtro de

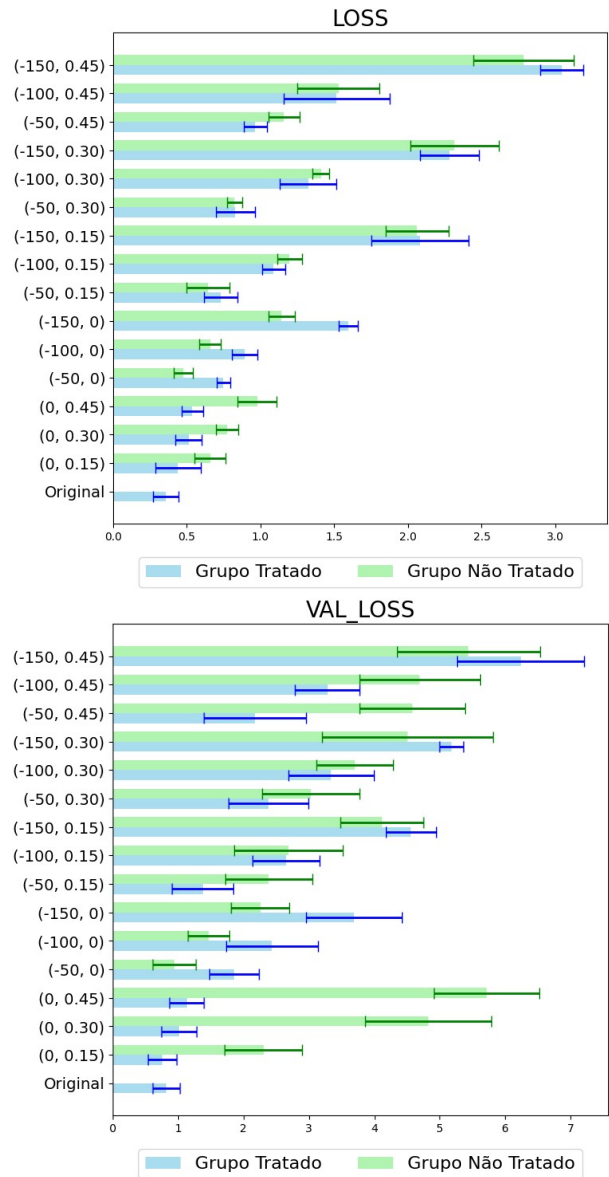
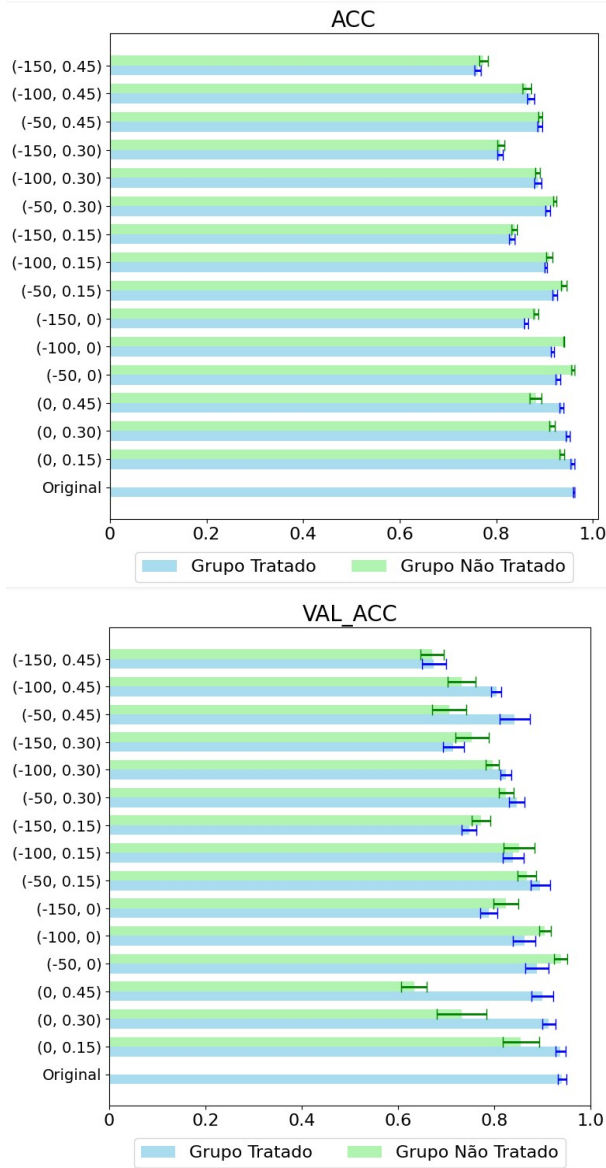


Figura 3. Representação gráfica comparativa dos valores de acurácia e acurácia de validação entre os grupos tratados e não tratados. Destaque para maior diferença nos grupos (0, 0.15), (0, 0.30) e (0, 0.45) do gráfico de Validação.

Figura 4. Representação gráfica comparativa dos valores de *loss* e *loss* de validação entre os grupos tratados e não tratados. Destaque para um valor de *loss* maior nos grupos que receberam tratamento e sofreram redução de brilho na imagem (-50, 0), (-100, 0), (-150, 0), (-150, 0.15), (-150, 0.30), (-150, 0.45) do gráfico de Validação.

desfoque mediano. Diferentemente da análise de acurácia e *loss* do modelo, o tratamento dos dados se mostrou eficaz na maioria dos casos. Vale ressaltar que nos dados dos conjuntos com redução de brilho entre -50 e -100, os quais conseguiram ultrapassar e igualar-se, respectivamente, às pontuações de F1 ponderado do conjunto sem tratamento.

Essa informação sugere que alguma classe do problema apresenta maior complexidade para a classificação quando a redução de brilho e/ou o tratamento são aplicados nos dados inseridos. Isso indica que o processo de pré-processamento com a redução de brilho pode estar introduzindo variações que tornam mais desafiadora a identificação correta das classes.

6.3. F1 – POR CLASSE

A análise comparativa do fator F1 de cada classe proporcionou uma visualização mais esclarecedora sobre os impactos na classificação. Nota-se, tanto nos gráficos comparativos da Fig. 6 quanto na Fig. 7, que a redução de brilho teve um impacto mais negativo na classificação da classe Packstone, enquanto as demais classes apresentaram maior complexidade quando foram inseridos ruídos *Salt-And-Pepper*. Essa tendência foi observada tanto no grupo tratado quanto no não tratado. A queda do F1 nos casos em que houve apenas redução de brilho sugere que o tratamento com equalização para essa redução específica de brilho não foi vantajoso para esse conjunto de dados. No entanto,

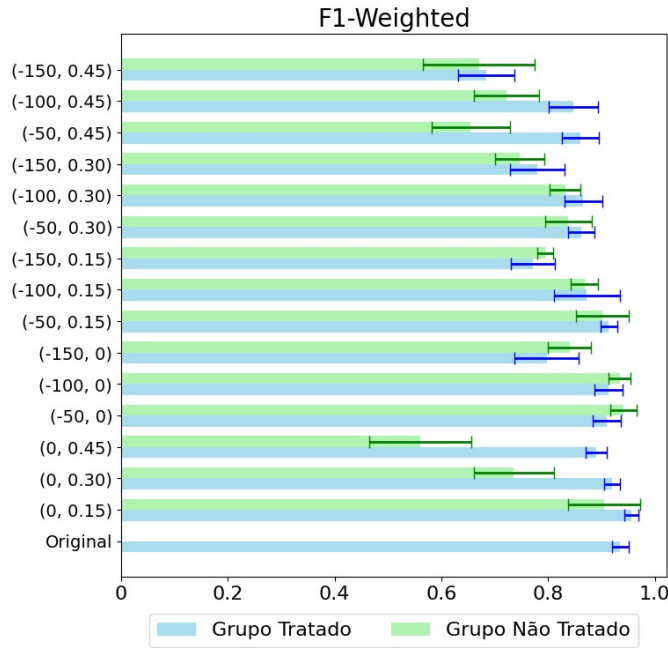


Figura 5. Representação gráfica comparativa dos valores de pontuação F1 ponderada dos 32 grupos treinados.

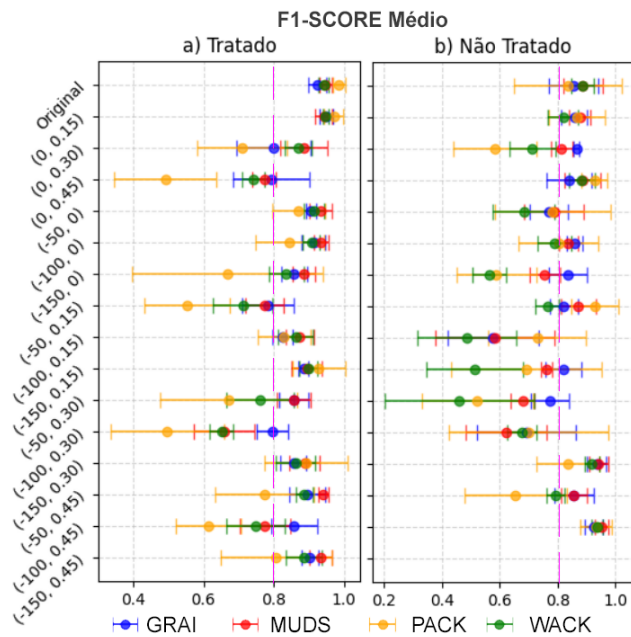


Figura 6. Comparação grupo a grupo dos valores de pontuação F1 médio de cada classe dos 32 grupos treinados. A linha vermelha vertical delimita a região de *F1-Score* 0.8. As linhas horizontais pontilhadas separam os grupos por conjuntos que variam a mesma grandeza.

quando houve a combinação de ruído e brilho, o tratamento conseguiu reduzir a queda em quase todas as classes, exceto na classe Packstone (que é a classe com a menor quantidade de imagens). Apesar de as classes Grainstone e Mudstone terem apresentado bom comportamento com o tratamento, as classes Packstone e Wackestone mostraram os menores

valores de F1 e não se beneficiaram tanto com o tratamento aplicado.

As tabelas da Fig. 7 mostram que quando há uma combinação de baixa redução de brilho com *Salt-And-Pepper*, a recuperação se apresenta mais eficaz que nos casos de maior redução de brilho, seja isolado ou combinado. Isto sugere que quando há alterações nos níveis de pixels, a estratégia mais vantajosa é tratar apenas o ruído granulado, quando este ocorre, em vez de buscar uma recuperação do brilho através da equalização do canal.

Apesar disso, o tratamento conseguiu manter o *F1-score* em aproximadamente 0.8 para a maioria dos casos em que o ruído e a redução de brilho não ultrapassaram 0.30 e -100, respectivamente.

F1-SCORE Médio										
	Grupo Não Tratado					Grupo Tratado				
	GRAIN	MUDS	PACK	WACK	WEIGHT	GRAIN	MUDS	PACK	WACK	WEIGHT
Original	0,92	0,95	0,99	0,94	0,94	0,92	0,95	0,99	0,94	0,94
(0, 0.15)	0,86	0,87	0,89	0,88	0,88	0,94	0,94	0,97	0,95	0,95
(0, 0.30)	0,76	0,79	0,72	0,68	0,75	0,92	0,93	0,87	0,91	0,92
(0, 0.45)	0,59	0,59	0,70	0,52	0,58	0,90	0,91	0,94	0,91	0,91
(-50, 0)	0,92	0,95	0,93	0,94	0,94	0,90	0,93	0,81	0,89	0,91
(-100, 0)	0,93	0,94	0,83	0,92	0,93	0,90	0,94	0,78	0,89	0,90
(-150, 0)	0,86	0,86	0,65	0,79	0,83	0,86	0,77	0,61	0,75	0,79
(-50, 0.15)	0,85	0,89	0,89	0,87	0,87	0,91	0,93	0,86	0,91	0,91
(-100, 0.15)	0,85	0,88	0,82	0,84	0,86	0,81	0,89	0,77	0,87	0,85
(-150, 0.15)	0,87	0,81	0,52	0,70	0,79	0,78	0,78	0,45	0,72	0,74
(-50, 0.30)	0,82	0,87	0,91	0,77	0,83	0,82	0,89	0,75	0,85	0,85
(-100, 0.30)	0,88	0,84	0,80	0,81	0,85	0,86	0,87	0,66	0,83	0,85
(-150, 0.30)	0,82	0,76	0,62	0,61	0,74	0,78	0,75	0,54	0,69	0,74
(-50, 0.45)	0,71	0,62	0,66	0,68	0,67	0,87	0,90	0,88	0,86	0,88
(-100, 0.45)	0,83	0,76	0,75	0,47	0,71	0,87	0,85	0,66	0,78	0,83
(-150, 0.45)	0,78	0,68	0,52	0,46	0,64	0,79	0,70	0,47	0,69	0,71

Figura 7. A imagem acima representa uma tabela com os valores de pontuação F1 médio de cada classe dos 32 grupos treinados. A escala de temperatura é individual em cada tabela e na última coluna apresenta o valor ponderado para comparação.

6.4. MATRIZ CONFUSÃO

Para realizar a análise da matriz confusão relacionada aos conjuntos de imagens treinados e validados, foi calculado a matriz média da validação cruzada e seus respectivos desvios padrões para visualizar os impactos das alterações realizadas nos mesmos conjuntos de imagens e seus respectivos tratamentos no desempenho do modelo de classificação. Inicialmente essa análise revela uma confusão entre a classe Mudstone e as classes Grainstone e Wackestone dentro dos conjuntos com apenas ruído *Salt-And-Pepper* inserido. Esta ocorrência é evidenciada pelos falsos positivos apresentados nas matrizes das Fig. 8. Vale ressaltar que a classe Packstone começou a ser confundida com Grainstone apenas para magnitudes de *Salt-And-Pepper* a partir de 30%. Contudo, como já confirmado em análises anteriores a Fig. 9 reforça a eficácia do tratamento em evidenciar as diferenças entre as classes de modo suficiente para minimizar os impactos desse tipo de ruído.

Já a análise das matrizes dos conjuntos apenas com redução de brilho, representadas nas matrizes na Fig. 10 e Fig. 11, revela um pequeno impacto dessa alteração nos

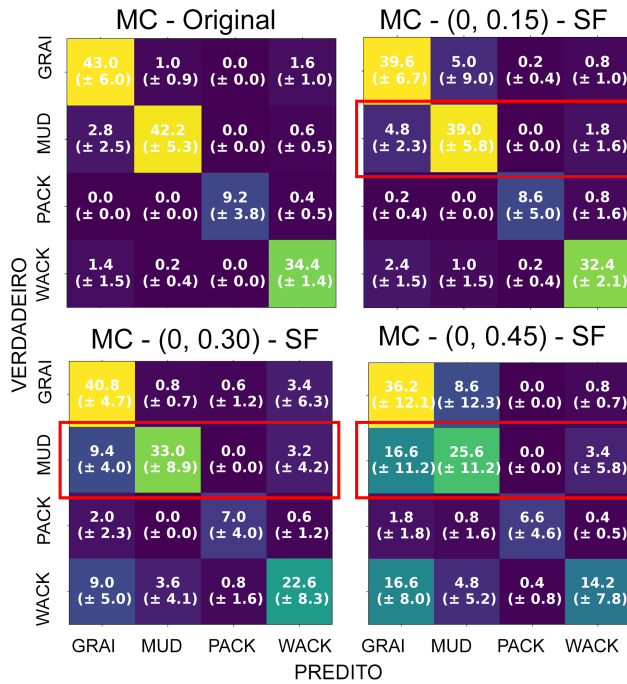


Figura 8. Visualização da matriz confusão do grupo original junto aos grupos somente com *Salt-And-Pepper* do grupo não tratado. O retângulo vermelho destaca confusão entre as classes de Mudstone e Grainstone e Wackestone e revela seu aumento progressivo proporcional a magnitude da probabilidade do ruído.




Figura 9. Visualização da matriz confusão do grupo original junto aos grupos somente com *Salt-And-Pepper* inserido e foram tratados pelo filtro de desfoque mediano. A figura apresenta evidente melhora na tarefa de classificação do modelo.

dados, principalmente na classe Packestone. No entanto, ao




Figura 10. Visualização da matriz confusão do grupo original junto aos grupos somente com redução de brilho do grupo não tratado.




Figura 11. Visualização da matriz confusão do grupo original junto aos grupos somente com redução de brilho do grupo tratado.

observar o desvio padrão, notamos que alguns folds apresentaram grandes diferenças em relação aos valores da matriz média, concordando com as análises anteriores, uma vez que elas demonstraram um grande impacto na redução do desempenho do modelo para essa classe na presença desse erro. A equalização apresentou uma alteração significativa apenas

com redução de brilho bastante elevada (-150), enquanto todas as classes sofreram pequenas perdas de desempenho. O tratamento, mais uma vez, mostrou-se como um fator complicador na tarefa de classificação do modelo, causando confusão mesmo na matriz com menor fator de redução.

Quando comparamos diretamente as matrizes de confusão que mostram as alterações combinadas do grupo não tratado (Fig. 12) com o grupo tratado (Fig. 13), torna-se evidente que, o tratamento acentuou a diferenciação entre as classes nas situações de baixa redução de brilho (-50). Essa diferença pode ser atribuída, em grande parte, à eficácia limitada da equalização de brilho neste conjunto de dados, o que é confirmado quando observamos que, no modelo não tratado, a coluna que representa apenas a redução de brilho obteve um desempenho superior em comparação com os demais conjuntos não tratados.

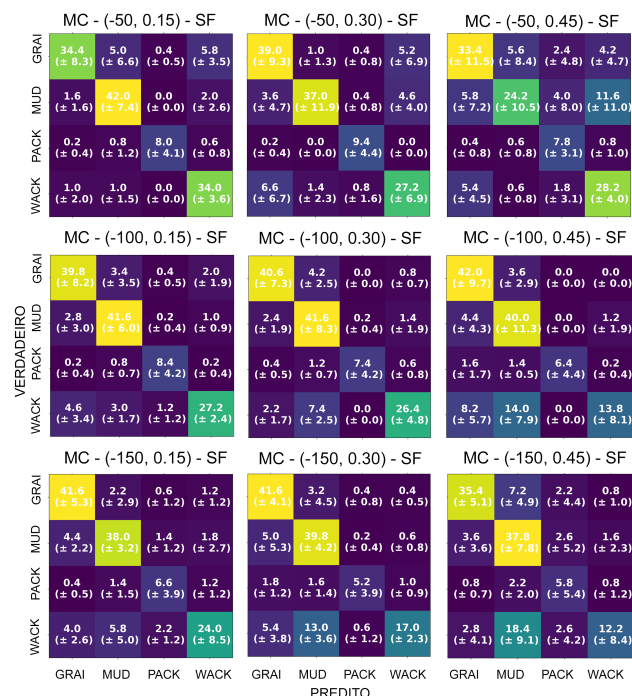


Figura 12. Representação da matriz confusão dos 9 experimentos com redução de brilho e ruído combinados e sem tratamento.

7. CONCLUSÃO

7.1. Há correlação entre a presença dos erros de aquisição aleatórios e de iluminação, assim como o seu impacto nas diferentes classes de rochas sedimentares carbonáticas dentro da classificação Dunham?

O estudo indica que as classes mais homogêneas (Mudstone e Grainstone) tendem a ser menos afetadas pelos erros introduzidos em comparação com as classes menos homogêneas (Packstone e Wackestone). No entanto, o desbalançamento na distribuição dos dados desempenha um papel

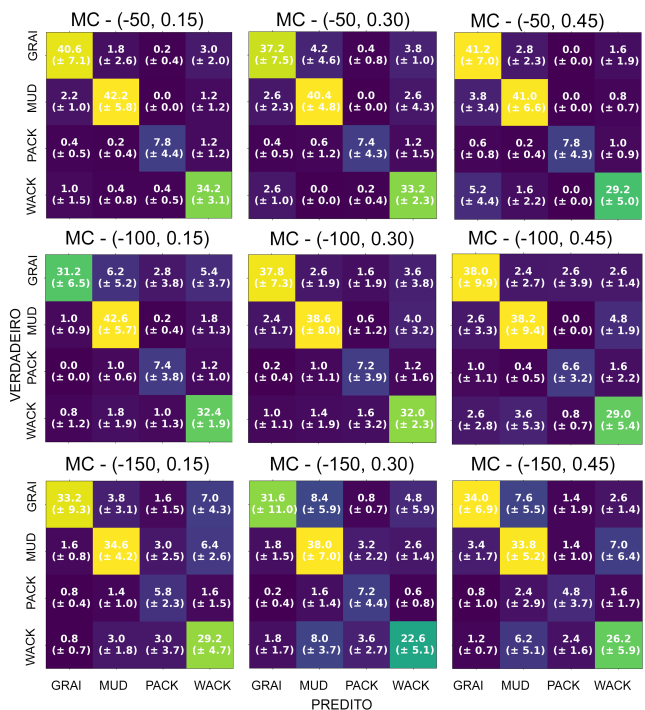


Figura 13. essa aqui Representação da matriz confusão dos 9 experimentos com redução de brilho e ruído combinados e tratados.

crucial na complexidade da classificação da classe Packstone, que apresentou resultados menos satisfatórios com a introdução dos erros. A representatividade limitada dessa classe nos *folds* da validação cruzada, certamente, contribuiu significativamente para esse efeito acentuado sobre a classe.

7.2. A equalização de brilho e os filtros de ruído recuperam a perda de performance por conta dos erros inseridos?

Quanto ao uso da equalização de brilho e dos filtros de ruído para recuperar a perda de desempenho, observou-se que o filtro de desfoque mediano mostrou-se altamente eficaz na recuperação da acurácia e na redução da *loss*, facilitando a tarefa de classificação do modelo. Esse resultado já era esperado, dada a natureza do ruído e a eficiência comprovada do filtro em outros trabalhos que não utilizaram a mesma base de dados. No entanto, a equalização de brilho por histograma do canal L do espaço de cores LAB não alcançou as expectativas e, pelo contrário, contribuiu para gerar maior complexidade na tarefa de classificação realizada pelo modelo nessa base de dados.

7.3. As classes se comportam de forma diferente em relação aos ruídos aplicados?

No que se refere ao comportamento das classes em relação aos diferentes tipos de ruído aplicados, observou-se que as classes menos homogêneas e com menor quantidade de im-

agens (Packestone e Wackestone) foram mais afetadas à redução de brilho. A classe Packestone sofreu um impacto considerável com uma redução de brilho de -100, enquanto o Wackestone se destacou em reduções ainda mais significativas. Por outro lado, a introdução do ruído "Salt-And-Pepper" afetou menos a classe Packestone quando a inten-

sidade do ruído era mais elevada em comparação com as outras classes. Quando houve a combinação dos erros inseridos, o impacto foi ainda mais pronunciado, resultando em uma diminuição de até 20% nos valores de F1 para cada classe, com as classes mais heterogêneas sofrendo as maiores penalizações novamente.

-
- [1] Guojian, Cheng, and Li Peisong. "Rock thin-section image classification based on residual neural network." 2021 6th International Conference on Intelligent Computing and Signal Processing (ICSP). IEEE, 2021.
- [2] Faria, E.L., Coelho, J.M., Matos, T.F. et al. Lithology identification in carbonate thin section images of the Brazilian pre-salt reservoirs by the computational vision and deep learning. *Comput Geosci* 26, 1537–1547 (2022). <https://doi.org/10.1007/s10596-022-10168-0>
- [3] Wu, Jiqing, et al. "On the relation between color image denoising and classification." arXiv preprint arXiv:1704.01372 (2017).
- [4] da Costa, Gabriel B. Paranhos, et al. "An empirical study on the effects of different types of noise in image classification tasks." arXiv preprint arXiv:1609.02781 (2016).
- [5] Erkan, Uğur, Levent Gökrem, and Serdar Enginoğlu. "Different applied median filter in salt and pepper noise." *Computers & Electrical Engineering* 70 (2018): 789-798.
- [6] David Menotti Gomes. Contrast enhancement in digital imaging using histogram equalization. Other [cs.OH]. Université Paris-Est, 2008. English. ffnnt : 2008PEST0226ff. fftel-00470545ff
- [7] Jawad, Emtinan & G., Hazim & Mohamad, Haidar. (2022). Retinal Image Enhancement by using Adapted Histogram Equalization based on Segmentation and Lab Color Space. 15. 614-622.
- [8] Erkan, Uğur, Levent Gökrem, and Serdar Enginoğlu. "Different applied median filter in salt and pepper noise." *Computers & Electrical Engineering* 70 (2018): 789-798.
- [9] S. Agarwal, "Data Mining: Data Mining Concepts and Techniques," 2013 International Conference on Machine Intelligence and Research Advancement, Katra, India, 2013, pp. 203-207, doi: 10.1109/ICMIRA.2013.45.
- [10] Witten, Ian H., et al. "Practical machine learning tools and techniques." *Data Mining*. Vol. 2. Morgan Kaufmann, 2016.
- [11] Goutte, Cyril, and Eric Gaussier. "A probabilistic interpretation of precision, recall and F-score, with implication for evaluation." *European conference on information retrieval*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2005.
- [12] Patro, V. Mohan, and Manas Ranjan Patra. "Augmenting weighted average with confusion matrix to enhance classification accuracy." *Transactions on Machine Learning and Artificial Intelligence* 2.4 (2014): 77-91.
- [13] S. Dodge and L. Karam, "Understanding how image quality affects deep neural networks," 2016 Eighth International Conference on Quality of Multimedia Experience (QoMEX), Lisbon, Portugal, 2016, pp. 1-6, doi: 10.1109/QoMEX.2016.7498955.
- [14] [14] Qi, Min, et al. "Multi-region nonuniform brightness correction algorithm based on L-channel gamma transform." *Security and Communication Networks* 2022 (2022).

Notas Técnicas é uma publicação de trabalhos técnicos relevantes, das diferentes áreas da física e afins, e áreas interdisciplinares tais como: Química, Computação, Matemática Aplicada, Biblioteconomia, Eletrônica e Mecânica entre outras.

Cópias desta publicação podem ser obtidas diretamente na página web <http://revistas.cbpf.br/index.php/nt> ou por correspondência ao:

Centro Brasileiro de Pesquisas Físicas
Área de Publicações
Rua Dr. Xavier Sigaud, 150 – 4^o andar
22290-180 – Rio de Janeiro, RJ
Brasil
E-mail: alinecd@cbpf.br/valeria@cbpf.br
<http://portal.cbpf.br/publicacoes-do-cbpf>

Notas Técnicas is a publication of relevant technical papers, from different areas of physics and related fields, and interdisciplinary areas such as Chemistry, Computer Science, Applied Mathematics, Library Science, Electronics and Mechanical Engineering among others.

Copies of these reports can be downloaded directly from the website <http://notastecnicas.cbpf.br> or requested by regular mail to:

Centro Brasileiro de Pesquisas Físicas
Área de Publicações
Rua Dr. Xavier Sigaud, 150 – 4^o andar
22290-180 – Rio de Janeiro, RJ
Brazil
E-mail: alinecd@cbpf.br/valeria@cbpf.br
<http://portal.cbpf.br/publicacoes-do-cbpf>