

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
INFORMÁTICA INDUSTRIAL**

ROMÁRIO KEITI PIZZATTO FUGITA

**PRIOR DE REGULARIZAÇÃO PARA PROBLEMA DE
DEMOSAICING COM APLICAÇÃO EM CFA'S VARIADOS**

DISSERTAÇÃO

CURITIBA

2016

ROMÁRIO KEITI PIZZATTO FUGITA

**PRIOR DE REGULARIZAÇÃO PARA PROBLEMA DE
DEMOAICING COM APLICAÇÃO EM CFA'S VARIADOS**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do grau de “Mestre em Ciências” – Área de Concentração: Engenharia Biomédica.

Orientador: Marcelo Victor Wüst Zibetti, Dr.
Eng.^o

Co-orientador: Daniel Rodrigues Pipa, Dr.

CURITIBA

2016

Dedico este trabalho ao meu falecido avô, que deixa muitas saudades. Ao meu orientador e coorientador por me guiarem com maestria. Também a meus pais pelo suporte onipresente, e à minha noiva por manter o meu foco.

AGRADECIMENTOS

Agradeço a Deus, por me permitir chegar aonde pude, e também aos que estiveram comigo durante toda a caminhada. Agradeço especialmente à Universidade Tecnológica Federal do Paraná e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, pela oportunidade de pesquisa oferecida.

O que é necessário não é a vontade de acreditar, mas o desejo de descobrir, que é justamente o oposto. (RUSSEL, Bertrand)

RESUMO

FUGITA, Romário K. P. PRIOR DE REGULARIZAÇÃO PARA PROBLEMA DE DEMOSAICING COM APLICAÇÃO EM CFA'S VARIADOS. 58 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2016.

Este trabalho tem por objetivo apresentar uma nova proposta aos algoritmos de *Demosaicing* existentes, utilizando uma abordagem mais flexível quanto ao uso do *Color filter array* (CFA) em imagens coloridas de único sensor. O algoritmo proposto tem como base a estrutura de problemas inversos, cujo funcionamento utiliza um modelo de operação matriz-vetor que é adaptável ao CFA empregado. A partir deste conceito, o algoritmo trata o problema de *Demosaicing* como o de minimização de função custo, com um termo referente à dependência da estimativa com os dados obtidos e com o modelo de captura, o outro termo é relacionado aos conhecimentos observados em imagens que podem ser explorados para uma estimativa mais precisa, tal elemento é chamado de *Prior*. A proposta estabelecida tem como base algoritmos de regularização com foco na alta correlação presente entre os canais de cor (R, G e B), e na suavidade local de regiões uniformes, essa base formaliza o *Prior* empregado no trabalho. A minimização da proposta é atingida iterativamente através do IRLS-CG, que é a combinação de dois algoritmos de minimização eficientes, que apresenta rápidas respostas, e a capacidade de trabalhar com a norma ℓ_1 em conjunto com a norma ℓ_2 . Com o intuito de atestar a qualidade do algoritmo proposto, foi elaborado um experimento em que o mesmo foi testado com diferentes CFAs e em situação com ruído gaussiano de 35dB e sem ruído algum em imagens da base de dados da Kodak, e os resultados comparados com algoritmos do estado-da-arte, no qual o desempenho da proposta apresentou resultados excelentes, inclusive em CFAs que destoam do padrão Bayer, que é o mais comumente usado na atualidade.

Palavras-chave: Demosaicing. Prior. CFA. IRLS-CG. Flexibilidade.

ABSTRACT

FUGITA, Romário K. P.. REGULARIZATION PRIOR TO DEMOSAICING PROBLEMS WITH VARIOUS CFA APPLICATION. 58 f. Dissertação – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica Federal do Paraná. Curitiba, 2016.

This research presents a new proposal to Demosaicing algorithms, using a more flexible approach to deal with the Color filter array (CFA) in single sensor color imaging. The proposed algorithm is structured in the inverse problems model, whose functions employ a CFA adaptive matrix-vector operational model. From this concept, the Demosaicing problem is treated as a cost function minimization with two terms, one referring to the dependence between the estimation and the data provided by the acquisition model, and other term related to features observed in images, which can be explored to form a more precise estimation, this last term is known as Prior. The established proposal is applied in regularization algorithms with focus on the high correlation among color channels (R, G, and B), and in the local smoothness of uniform regions. Both characteristics organize the Prior employed in this work. The minimization proposed is iteratively achieved through IRLS-CG, which is the combination of two efficient minimization algorithms, that presents quick responses, and the capacity to deal with ℓ_1 and ℓ_2 norm at the same time. The quality of the proposed algorithm is verified in an experiment in which various CFA were used and a situation with 35dB gaussian noise and another one with no noise applied to the Kodak dataset, and the results were compared with state-of-the-art algorithms, in which the performance of the proposed Prior showed excellent results, including when the CFA is different from Bayer's, which is the most commonly used pattern.

Keywords: Demosaicing. Prior. CFA. IRLS-CG. Flexibility

LISTA DE FIGURAS

FIGURA 1	– Fluxograma das etapas de processamento da captura de uma imagem digital colorida. (Fonte: (RAMANATH et al., 2005), tradução do autor) ..	13
FIGURA 2	– Esquemático construtivo do painel de captura de Bayer no sensor de imagens coloridas.	14
FIGURA 3	– Esquemático de captura simulada em ambiente virtual.	16
FIGURA 4	– O efeito de <i>Blurring</i> em imagens coloridas	19
FIGURA 5	– O efeito do tempo de abertura em imagens coloridas.	20
FIGURA 6	– O efeito do ruído em imagens coloridas.	20
FIGURA 7	– Gráfico de resposta dos sensores de cada cor do CFA em função da frequência de onda luminosa.	23
FIGURA 8	– Disposição do padrão de CFA Bayer	24
FIGURA 9	– Disposição do padrão de CFA RGBE	24
FIGURA 10	– Disposição do padrão de CFA RGBW	24
FIGURA 11	– Disposição do padrão de CFA CYGM	24
FIGURA 12	– Análise unidimensional da interpolação linear, e seus efeitos em bordas.	28
FIGURA 13	– Esquemático de funcionamento do algoritmo de interpolação direcionada a bordas de Laroche e Prescott.	29
FIGURA 14	– Esquemático de funcionamento do algoritmo de interpolação direcionada a bordas de Hamilton e Adams.	30
FIGURA 15	– Esquemático de funcionamento do algoritmo DLMMSE de Zhang e Wu (2005)	31
FIGURA 16	– Esquemático de funcionamento do algoritmo LPA-ICI de Paliy et al. (2007)	32
FIGURA 17	– Espaço formado pela diferença de cor, R-G e B-G.	35
FIGURA 18	– Espaço formado pelas diferenças finitas verticais e horizontais dos PDS.	36
FIGURA 19	– Histogramas dos planos formados pelas diferenças finitas direcionais dos PDS em escala logarítmica	37
FIGURA 20	– Compilação dos <i>patches</i> utilizados no experimento.	48
FIGURA 21	– Comparativo de reconstruções sem ruído no padrão Bayer	51
FIGURA 22	– Comparativo de reconstruções sem ruído no padrão RGBW	52
FIGURA 23	– Comparativo de reconstruções sem ruído no padrão CYGM	52
FIGURA 24	– Comparativo de reconstruções com ruído no padrão Bayer	52
FIGURA 25	– Comparativo de reconstruções com ruído no padrão RGBW	53
FIGURA 26	– Comparativo de reconstruções com ruído no padrão CYGM	53

LISTA DE TABELAS

TABELA 1	– Valores médios de tempo computacional (segundos), PSNR (dB) e SSIM, para todas as imagens do experimento com os CFAs Bayer, RGBW e CYGM sem inserção de ruído, com destaques para as melhores performances nas três métricas apresentadas de cada CFA, e os Priors numerados correspondem respectivamente às Equação (14), (15) e (16).	50
TABELA 2	– Valores médios de tempo computacional (segundos), PSNR (dB) e SSIM, para todas as imagens do experimento com os CFAs Bayer, RGBW e CYGM com inserção de ruído gaussiano equivalente a 35 dB, com destaques para as melhores performances nas três métricas apresentadas de cada CFA, e os Priors numerados correspondem respectivamente às Equação (14), (15) e (16).	51

LISTA DE SIGLAS

CFA	<i>Color Filter Array</i>
CCD	<i>Charged Couple Device</i>
CMOS	<i>Complementary Metal-Oxide-Semiconductor</i>
CC	<i>Coeficiente de Correlação de Pearson</i>
SSIM	<i>Structural Similarity</i>
PSNR	<i>Peak Signal-to-Noise Ratio</i>
MSE	<i>Mean Square Error</i>
IRLS-CG	<i>Iteratively Reweighted Least-Squares Conjugate Gradient</i>
SNR	<i>Signal-to-Noise Ratio</i>
RGBW	<i>Red Green Blue White</i>
CYGM	<i>Cyan Yellow Green Magenta</i>
RGBE	<i>Red Green Blue Emerald</i>
PDS	<i>Primary Difference Signal</i>
DLMMSE	<i>Directional Linear Minimum Mean Square Error</i>
LPA	<i>Local Polynomial Approximation</i>
ICI	<i>Intersection of Confidence Intervals</i>
IRLS	<i>Iteratively Reweighted Least Squares</i>
TV	<i>Total Variation</i>
SA	<i>Sucessive Approximation</i>
SD	<i>steepest descent</i>
CG	<i>Conjugate Gradient</i>

SUMÁRIO

1	INTRODUÇÃO	12
1.1	MOTIVAÇÃO	17
1.2	OBJETIVOS	17
1.2.1	Objetivo Geral	17
1.2.2	Objetivos Específicos	17
1.3	ORGANIZAÇÃO DO TRABALHO	18
1.4	CONTRIBUIÇÃO	18
2	AQUISIÇÃO	19
2.1	MODELO DE CAPTURA	21
2.2	ARRANJOS DE FILTROS DE COR - COLOR FILTER ARRAY (CFA)	24
3	MÉTODOS DE DEMOSAICING	27
3.1	INTERPOLAÇÃO DIRECIONADA A BORDAS - LAROCHE, PRESCOTT	27
3.2	INTERPOLAÇÃO DIRECIONADA A BORDAS - HAMILTON, ADAMS	28
3.3	INTERPOLAÇÃO ADAPTATIVA (DLMMSE) - ZHANG, WU	29
3.4	INTERPOLAÇÃO ADAPTATIVA (LPA-ICI) - PALIY, DMITRIY	30
4	PROBLEMAS INVERSOS	33
4.1	PRIOR	34
4.2	<i>EXTENDED TOTAL VARIATION</i> - (??)	39
4.3	ALGORITMO ITERATIVO	39
5	PROPOSTA	42
5.1	<i>PRIOR</i> PROPOSTO	42
5.1.1	<i>Prior</i> Correlativo - P_C	43
5.1.2	<i>Prior</i> Espacial - P_E	43
5.1.3	Proporção entre P_C e P_E	44
6	EXPERIMENTOS	47
6.1	RESULTADOS	49
7	CONCLUSÃO	54
7.1	TRABALHOS FUTUROS	55
	REFERÊNCIAS	57

1 INTRODUÇÃO

Imagens digitais são a representação discreta dos elementos luminosos presentes em um cenário com objetos, dessa forma, a cor de cada pixel tem diferentes aspectos que devem ser mostrados. Por trás da formação da imagem completa em cores totalmente preenchida com seus elementos de imagem, *pixels*, há uma série de etapas que podem ser resumidas conforme o fluxograma 1 a seguir:

No fluxograma em 1, o processo é dividido em várias etapas, inicialmente, tem-se a formação dos dados, cuja qualidade e precisão é o resultado do controle focal em conjunto com o controle de exposição dos sensores, que determinam o espalhamento da luz correspondente de um pixel através do foco, e a quantidade de fótons que são recebidos pelo tempo de abertura. Imagens coloridas têm a característica de utilizar três informações para localizar a cor específica apresentada em cada *pixel*, o que as três informações representam é diferente para cada modelo de representação utilizado. Por exemplo, em imagem RGB elas representam a intensidade de cor vermelha, verde e azul respectivamente, em imagem HSV, a representação consiste de matiz, saturação e valor. Assim, para apresentar as três informações de um mesmo *pixel*, é preciso coletar esses dados utilizando três sensores um para cada variável, ou é coletada uma das informações enquanto as outras são estimadas. A segunda opção apresentada é a chamada de captura de sensor único, e ela tem em sua estrutura um elemento chamado de *Color Filter Array* (CFA). O CFA tem a função de ordenar a coleta de dados de modo que exista uma ciclicidade na coleta de cada um dos três componentes, de modo que o sensor de um *pixel* apresente uma das três informações enquanto as outras três são calculadas mais tarde, na etapa de *Demosaicing*.

Assim, imagens coloridas são formadas pela composição de três dados distintos, representados pela informação de quantidade de vermelho, verde e azul (R, G e B respectivamente, das iniciais das cores em inglês, *red*, *green* e *blue*, para representação em modelo RGB). A captura dos mesmos pode ocorrer de duas maneiras:

- Simultânea: em que ocorre a amostragem de todas as informações de cada *pixel* da ima-

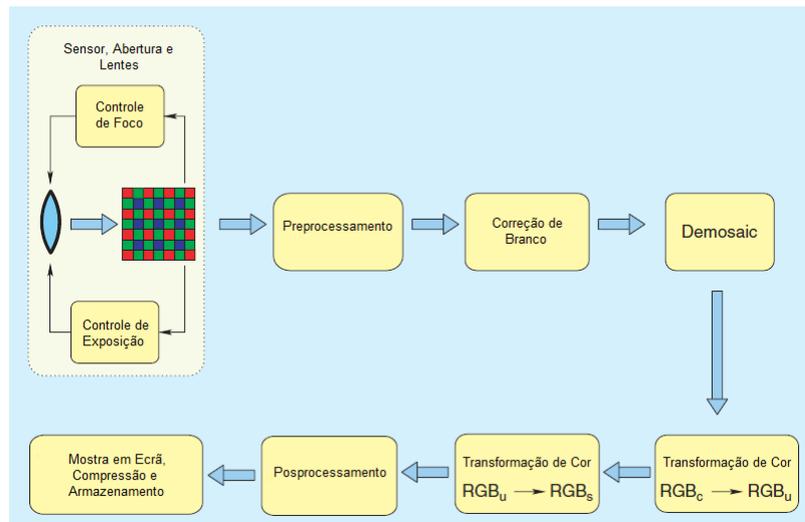


Figura 1: Fluxograma das etapas de processamento da captura de uma imagem digital colorida. (Fonte: (RAMANATH et al., 2005), tradução do autor)

gem. Para isso a câmera precisa dispor de três sensores para cada pixel, normalmente utiliza-se *charged couple device* (CCD) ou *complementary metal-oxide-semiconductor* (CMOS). Para diferenciar o canal do sinal recebido em cada um dos sensores, também há a necessidade de filtros de cor que permitam que somente as informações desejadas (R, G ou B) sejam coletadas, como visto na Figura 2.

- Alternada: em que cada *pixel* apresenta informação de uma cor de acordo com a cor do filtro empregado. O filtro aplicado é chamado de CFA, e ele apresenta um padrão de cor que se estende por toda a imagem, dando aos dados capturados um aspecto de mosaico. A função do CFA é promover uma captura homogênea de uma das informações específicas por toda a imagem, ainda que não seja em todos os *pixels* da mesma. Com o disposição do padrão do CFA, o preenchimento dos elementos faltantes com as estimativas é possível, e é realizado no ambiente de processamento da câmera. Esse processo de estimativa das informações que não foram obtidas na captura dos dados é conhecido por *Demosaicing*.

Por que precisamos do CFA na formação de imagens coloridas? Para produzir uma imagem colorida, deveria haver pelo menos três amostras de cor a cada posição de *pixel*. Uma abordagem é usar divisores de feixe ao longo do caminho óptico para projetar a imagem em três sensores separados [...]. Usando um filtro de cor na frente de cada sensor, são obtidos três canais completos da imagem colorida. Esta é uma abordagem custosa, por necessitar três sensores CCD, e além disso eles devem ser alinhados precisamente (o que é um desafio não-trivial em design mecânico). Uma solução com melhor relação custo-benefício é inserir um CFA na frente do sensor e capturar um componente de cor em uma posição do *pixel* e então interpolar os dois componentes faltantes. Devido ao padrão de mosaico do CFA, este processo interpolativo tem sido conhecido como *Demosaicing*. (LI et al., 2008)

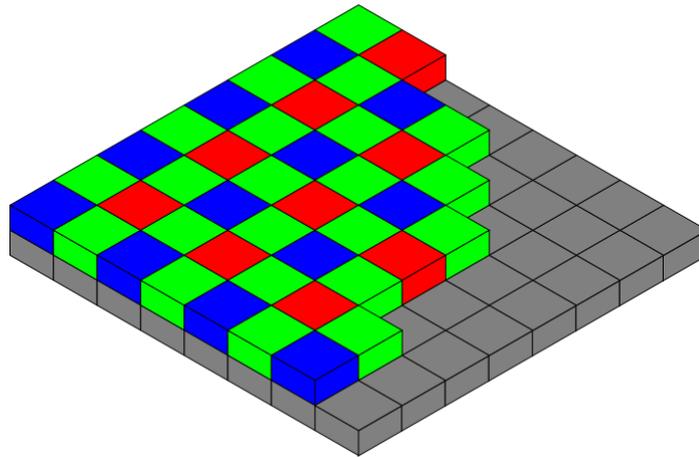


Figura 2: Esquemático construtivo do painel de captura de Bayer no sensor de imagens coloridas.

Após a coleta dos dados se necessita de um processamento antes do cálculo das estimativas do *Demosaicing*, Ramanath et al. (2005) mencionam a utilização de quatro das diversas correções que podem ser aplicadas. Sendo elas a detecção de *pixel* defeituoso, a linearização, balanço de branco, e corrente escura, dos quais os dois últimos representam respectivamente compensação de elementos próximos da saturação e compensação de captura no escuro, sem imagem. Está também incluso nesses procedimentos o tratamento de ruído inerente dos componentes estruturais do sensor.

Uma vez que os dados já tenham sido preprocessados e balanceados, eles já estão prontos para serem utilizados como base para as estimativas das informações faltantes de cada *pixel*. O processo responsável por esse cálculo de estimativa é o *Demosaicing*, conforme já mencionado, e ele pode ter como parâmetros várias características diferentes dependendo da relevância que é dada para essas características. Alguns trabalho em *Demosaicing* tem como base uma medida de homogeneidade, como Hirakawa e Parks (2005), muitos já optam pela correlação existente entre as cores vermelha, verde e azul do modelo de representação RGB, como Zhang et al. (2012), Paliy et al. (2007) e Saito e Komatsu (2008), há também abordagens estocásticas e por filtros dos mais diversos, uma comparação entre alguns dos vários métodos para *Demosaicing* pode ser encontrado no trabalho de Gunturk et al. (2005).

Por essa razão, *Demosaicing* é um problema com inúmeras possíveis soluções, pois cada método que existe produz uma solução diferente, e todas elas são plausíveis de acordo com os dados trabalhados. Em outras palavras, dependendo dos dados obtidos no sensor, filtrados pelo CFA, e do método de *Demosaicing* utilizado se tem um resultado único.

Seguindo ainda o fluxograma da Figura 1, depois do processo de *Demosaicing* estar concluído, chega-se à etapa das transformações de cor, em que se faz as projeções entre os

modelos de representação de cor existentes conforme o que se planeja mostrar ou o formato que se pretende armazenar a imagem. Inclusive alguns procedimentos podem ser efetuados como pós-processamento, por exemplo o aprimoramento de bordas, a redução de efeito zíper e enriquecimento de detalhes, chamado de *coring*.(GUNTURK et al., 2005)

Quando se obtém resultados de dois métodos diferentes é possível comparar ambos. Essa comparação, como pode ser visto na Figura 1, é o que estima a qualidade do procedimento, através dela é possível afirmar que um dos algoritmos foi melhor tanto subjetivamente, com aspectos visuais mais agradáveis e fidedignos com a imagem que se deseja capturar, ou objetivamente, ou seja, com o uso de métricas comparativas como índices de semelhança.

Neste trabalho utilizou-se o conceito de captura simulada, onde as operações do sistema foram realizadas todas em ambiente virtual, ou seja, a imagem digital já existe em computador e é nesse ambiente que a coleta dos dados e a estimativa da solução ocorrem. Isso quer dizer que a partir de uma imagem digital foi simulado o processo de captura com um determinado CFA gerando os dados com os quais se trabalhou para estimar uma solução. Este tipo de abordagem permite a utilização de CFAs diferentes para um mesmo conjunto de lentes e sensor, configurados nos parâmetros, que em uma situação real beira a impraticabilidade porque os CFAs são embutidos aos sensores no processo construtivo. Através da utilização de CFAs diferentes para parâmetros iguais de captura, é possível comparar as estimativas de um CFA em relação a outro diferente. Comparar imagens estimadas visualmente tende a deixar a avaliação muito subjetiva, com conclusões que variam de acordo com o observador, por essa razão é preciso de uma medida quantitativa, preferencialmente numérica, para as estimativas, uma avaliação objetiva da qualidade de todo o processo. Com um resultado baseado em avaliação numérica, a comparação consegue determinar o melhor desempenho com pouca margem para contestação, se houver alguma.

Reitera-se neste momento que a captura é simulada, assim, a imagem digital em que foi simulada a captura pode ser utilizada como referencial para determinar que CFA obteve melhor desempenho. De maneira que quanto mais próxima uma estimativa estiver da imagem original, melhor foi o desempenho. Na literatura já existem métricas de qualidade diversas, como mostrado por Zampolo et al. (2009): o Coeficiente de Correlação de Pearson CC, Similaridade Estrutural SSIM, Razão de Sinal-Ruído de Pico PSNR, Erro Quadrático Médio MSE. Apesar de todas as possibilidades para métricas de qualidade objetivas, no presente trabalho optou-se pelo PSNR e pela SSIM, o primeiro pela vasta utilização já presente na literatura (OPPENHEIM et al., 2010) e o segundo pela maior sensibilidade a artefatos e variações subjetivas que o PSNR ignora em algumas condições. (WANG et al., 2004)

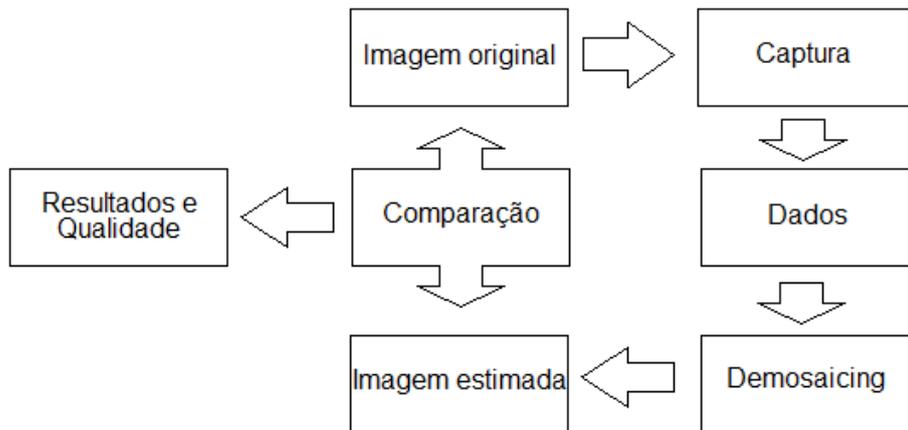


Figura 3: Esquemático que mostra o funcionamento da simulação da captura empregada no trabalho, por se tratar de um ambiente virtual, é possível a comparação numérica entre a imagem estimada e a imagem original.

As vantagens de se operar desta maneira são:

- Potencial do sistema depende da modelagem do problema - com um problema bem modelado se tem um sistema coerente com a realidade e as simulações apresentam resultados mais confiáveis.
- É possível estabelecer um método de comparação quantitativa - com resultados que comprovem numericamente a qualidade de sistemas, permitindo a constatação de sistemas mais eficientes.
- Aplicabilidade de diversas soluções matemáticas - neste caso, uma vez que sua eficiência já foi verificada em outros problemas.

A dificuldade de eleger um CFA mais apropriado para cada imagem que se deseja capturar vem do algoritmos existentes de *Demosaicing*, pois os mesmos são feitos para situações muito específicas de CFA, nas quais se aplicadas em dados provenientes de um CFA diferente apresenta uma resposta incoerente. Frente a essa dificuldade, se destaca como ponto importante desta pesquisa a busca de um algoritmo versátil o bastante para ter um desempenho bom quando se utiliza padrões de diferentes de CFA. Em que o processo de *Demosaicing* não esteja condicionado exclusivamente a um CFA. Isso permite verificar se em uma situação de ruído, imagem original, função de espalhamento, e parâmetros do algoritmo idênticos, variando apenas o CFA, se há diferença de performance e qualidade das estimativas. A versatilidade foi encontrada em

soluções de problemas inversos, que resume todo o processo de captura em operações matriz-vetor, em que os *pixels* são considerados dados de vetor e as transformações aplicáveis são as matrizes. De modo que basta informar como os dados foram coletados na aquisição, o CFA utilizado, que o algoritmo estima um operador que busca a transformação inversa à captura. Este operador consegue calcular uma imagem de resultado com qualidade muito boa ao ser aplicado nos dados conseguidos com a aquisição.

1.1 MOTIVAÇÃO

A utilização de soluções para problemas inversos em outras aplicações: ultrassom (ZANNIN et al., 2011), ressonância magnética (ZIBETTI; De Pierro, 2010), tomografia (HERMAN; KUBA, 2003), superresolução (ZIBETTI, 2003) apresentou bons resultados. O mesmo é esperado para o problema de *Demosaicing*, conforme (SAITO; KOMATSU, 2008) assim, há a necessidade de se comparar resultados do estado da arte com soluções para problemas inversos. Outra necessidade é a capacidade de um sistema de reconstrução ser aplicável a outros padrões de CFA, gerando assim um sistema flexível e versátil, cujas reconstruções podem ser utilizadas para comparar a qualidade do CFA usado na captura. Possibilitando a criação de um maneira numérica para mensurar a qualidade de um CFA, que imagens são melhor capturadas com cada CFA, e que CFA é o mais adequado para a imagem que se deseja capturar.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Elaborar um algoritmo de reconstrução para o problema de *Demosaicing*, utilizando a solução de problemas inversos, que seja flexível quanto ao padrão de CFA utilizado e apresente boa qualidade.

1.2.2 OBJETIVOS ESPECÍFICOS

- Estruturar um algoritmo de minimização utilizando o método IRLS-CG com bons resultados.
- Propor um termo de regularização capaz de proporcionar uma minimização rápida, coerente e estável.
- Comparar resultados obtidos de PSNR e SSIM (WANG et al., 2004) entre algoritmos do estado da arte, com o algoritmo apresentado neste trabalho.

- Verificar a tendência de qualidade dos resultados em função do padrão de CFA utilizado, e elaborar conclusões sobre o que foi observado.

1.3 ORGANIZAÇÃO DO TRABALHO

O presente trabalho é dividido da seguinte forma:

Capítulo 2 - As características do processo de aquisição dos dados para imagens capturadas com o uso do CFA, verifica-se nesse capítulo detalhes importantes como o modelo de captura empregado no trabalho e a importância do CFA utilizado na aquisição.

Capítulo 3 - Há a apresentação de soluções de *Demosaicing* já existentes, com qualidade de resultados comprovados e aceitos na comunidade científica.

Capítulo 4 - É abordado o conceito de problema inverso que será empregado na solução proposta.

Capítulo 5 - São verificados os detalhes do algoritmo proposto, com Problemas Inversos e *Priors*.

Capítulo 6 - Compara-se os resultados do algoritmo proposto com os outros métodos descritos no terceiro capítulo em um experimento.

Capítulo 7 - São apresentadas as conclusões da pesquisa.

1.4 CONTRIBUIÇÃO

A proposta do trabalho trata do problema de *Demosaicing* como um problema inverso e para atingir resultados melhores, explora-se informações presentes na diferença entre canais de cor e na suavidade local de imagens naturais. A contribuição que o trabalho oferece se encontra na versatilidade de se operar com CFAs diferentes, uma vez que o CFA com o qual se deseja trabalhar esteja previsto na operação do problema, o algoritmo proposto é capaz de produzir resultados razoáveis. O desempenho do algoritmo já se mostrou eficaz na comunidade científica, inclusive com a aprovação em congresso de visão computacional. (FUGITA et al., 2015)

2 AQUISIÇÃO

Neste capítulo pretende-se verificar como ocorre a geração dos dados, quais os pontos importantes e como é tratada a aquisição dos dados no modelo de captura empregado no trabalho.

A captura de imagens coloridas com sensor único precisa de um painel para determinar qual a intensidade de determinados canais de cor observados em cada posição específica do sensor. Foi visto também que há diversas possibilidades para o CFA e a escolha correta do CFA influencia na qualidade do resultado, visto que existem vários modos de se estimar os *pixels* faltantes da imagem e os dados utilizados para calcular essa estimativa dependem do CFA.

Verifica-se a existência de algumas variáveis dentro do processo de aquisição de dados da imagem, como: foco das lentes, tempo de exposição, CFA utilizado, iluminação da imagem. Enfim, todas elas influenciam nos dados obtidos. O foco das lentes tem relação com o *blurring* presente na imagem que dá aos dados uma aparência suave, como visto na Fig. 4. Em Bovik (2000), o autor descreve vários métodos de reduzir os efeitos do *blurring*, a partir de filtros inversos e filtros iterativos.

O tempo de abertura interfere na intensidade de luz recebida em cada sensor. Um

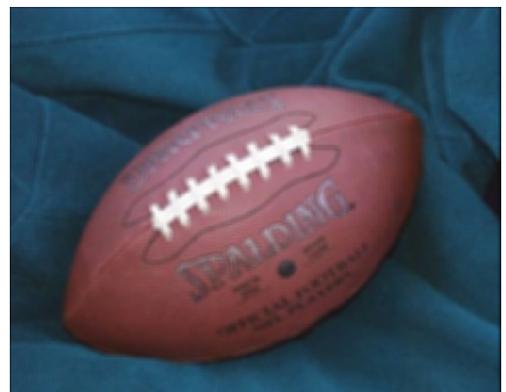
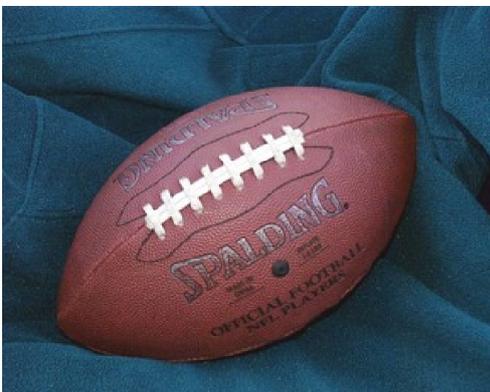


Figura 4: À esquerda há uma imagem digital sem *blurring*, à direita a mesma imagem com aplicação do *blurring*. Em imagens digitais, ocorre a suavização da mesma o que causa a perda de detalhes.



Figura 5: À esquerda há uma imagem digital com baixo tempo de abertura, à direita a mesma imagem com efeito de tempo de abertura elevado. Em imagens digitais, ocorre a saturação de *pixels* claros com alta abertura e o escurecimento da imagem com abertura insuficiente.

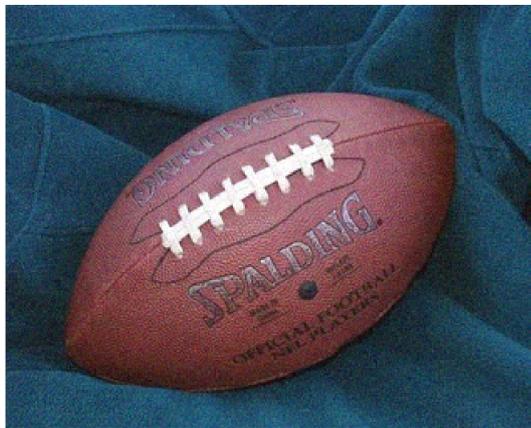


Figura 6: Detalhes de imagem sujeita a ruído gaussiano com *Signal-to-Noise Ratio* (SNR) equivalente a 20 dB.

tempo muito curto causa pouca intensidade de sinal o que requer que o sinal seja amplificado em conjunto com o ruído que acaba diminuindo a consistência dos dados. Em contrapartida, tempo muito longo de exposição gera a saturação de elementos, começando pelos *pixels* mais claros. Tais situações podem ser verificadas na Fig. 5.

Semelhante à situação do tempo de exposição em excesso, a iluminação do cenário também envolve a quantidade e qualidade da energia que é recebida no sensor. Pela escassez de luz que alcança o sensor, há uma compensação no mecanismo da captura, o tempo de exposição é aumentado propositalmente para a formação da imagem. Esse processo é encontrado com frequência em fotografias astronômicas, onde a fonte luminosa, estrelas distantes, são fracas e precisam de um tempo maior para que uma imagem razoável seja formada.

Outro aspecto presente é o ruído, que é um elemento de origem aleatória, responsável por distorções dos valores dos *pixels* capturados, como mostrado na Figura 6. Existem três exemplos mais comuns de ruído (CAMBRIDGE... , 2015) , os quais consistem em ruído com

padrão fixo, ruído aleatório e em bandas, cada um deles possui características diferentes. O ruído de padrão fixo é inerente ao *hardware* de captura, a presença de falhas nesse equipamento produz elementos distorcidos na imagem que são reincidentes em uma segunda captura sob as mesmas condições. Devido a esse comportamento previsível, tem-se que o ruído de padrão fixo é considerado como um ruído de recuperação mais simples.

Outra situação é o ruído aleatório, em que o mesmo é representado por flutuações de comportamento inesperado em torno dos valores esperados. Mesmo sob as mesmas condições de uma primeira captura, o ruído aleatório não será o mesmo em ambas as capturas. (CAMBRIDGE... , 2015)

2.1 MODELO DE CAPTURA

O modelo de captura depende da aquisição de dados, neste trabalho o modelo teve como princípio a operação de seleção e amostragem realizada pelo CFA empregado. Onde, conforme a Eq. (1), de acordo com a cor do painel do CFA que captura um pixel na posição de coordenadas (i,j) os elementos h_R , h_G e h_B assumem os valores que combinados são capazes de formar a cor correspondente do CFA.

$$g(i, j) = h_R \cdot f_R(i, j) + h_G \cdot f_G(i, j) + h_B \cdot f_B(i, j) \quad (1)$$

Ao se utilizar uma base de conotação em operação matriz-vetor de um processo de aquisição de dados similar ao problema de subamostragem sob a ótica de problemas inversos. Assim, a operação em termos de função de captura é composta pelos elementos capturados g em todas as posições (i, j) que compõe a imagem, que são resultado do operador h sobre a informação total, f , como pode ser verificado na Eq. (2).

$$g = \begin{bmatrix} h_R & h_G & h_B \end{bmatrix} \begin{bmatrix} f_R \\ f_G \\ f_B \end{bmatrix} \quad (2)$$

Dessa forma, neste trabalho foi utilizada representação de modelo linear, em que as imagens são transformadas em vetores de dados e as operações de tratamento desses dados (*denoising*, *deblurring*, *demosaicing*) são operações matriz-vetoriais. São várias as vantagens de se trabalhar segundo este modelo, uma delas, por exemplo, é a facilidade de manipular os dados e elaborar operadores mais específicos para atuar em cada etapa do processo de reconstrução,

ou seja, dividir o processo todo em várias etapas e aplicá-las uma a uma, possibilitando o acompanhamento em cada estágio da reconstrução. O modelo de captura empregado é desenvolvido a partir da Eq. (2) e é descrito pela Eq. (3):

$$\mathbf{g} = \mathbf{H}\mathbf{f} + \mathbf{n} \quad (3)$$

Abaixo, na Eq. (4), segue um esquemático com o exemplo do funcionamento do processo de aquisição de uma imagem de 2x2 pixels utilizando o padrão de CFA RGBW. Pode-se perceber a transformação dos dados bidimensionais com 3 canais de cor em um vetor unidimensional no qual se aplica a captura dos dados de acordo com o CFA escolhido, no exemplo RGBW.

$$\mathbf{g} = \begin{bmatrix} r_1 + g_1 + b_1 \\ b_2 \\ r_3 \\ g_4 \end{bmatrix} = \mathbf{H}\mathbf{f} = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} r_1 \\ r_2 \\ r_3 \\ r_4 \\ g_1 \\ g_2 \\ g_3 \\ g_4 \\ b_1 \\ b_2 \\ b_3 \\ b_4 \end{bmatrix} \quad (4)$$

De acordo com o modelo descrito, há uma imagem que se deseja produzir digitalmente, representada por \mathbf{f} . Esta imagem sofre a captura, em que estão inclusas as diversas variáveis descritas no início deste capítulo, representada pelo operador \mathbf{H} , o que resulta nos dados disponíveis para a reconstrução da imagem, adotado como por \mathbf{g} . Mais adiante será utilizado o conceito de operador inverso como recurso de reconstrução para recuperar a imagem anterior à captura a partir dos dados disponíveis.

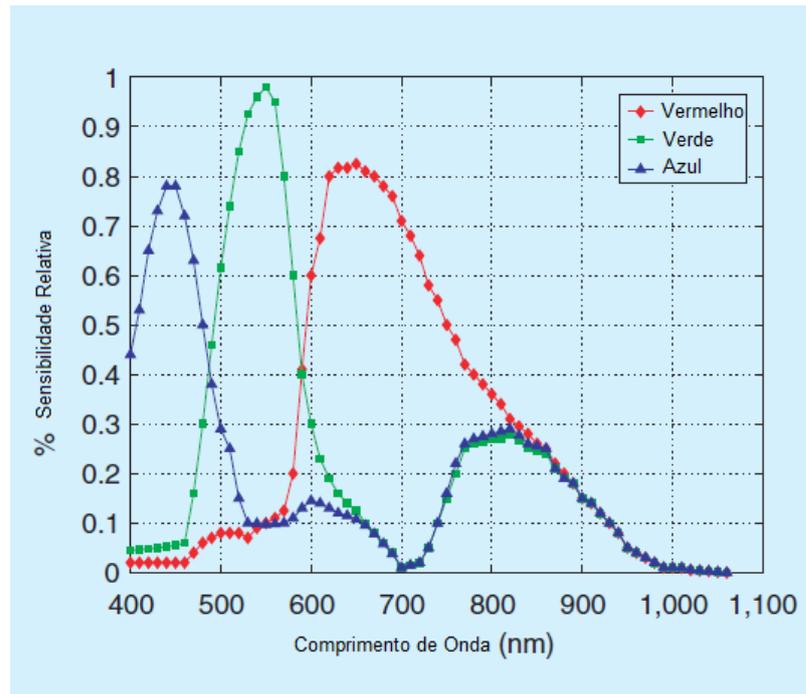


Figura 7: Gráfico presente em Ramanath et al. (2005) que mostra a sobreposição da resposta dos painéis do sensor Bayer, pode-se perceber a região no gráfico em que o sinal do sensor permeia os sinais vizinhos, dando aos diferentes canais do sinal capturado uma correlação elevada.

Uma característica de grande relevância é a representação digital da imagem natural, cujas cores apresentam níveis discretos determinados pelo padrão de representação. processo de filtragem pelo CFA, que, embora tenha função de amostragem exclusiva de um canal de cor específico, as frequências das ondas luminosas ultrapassam os limites das cores vizinhas como pode ser visto na Fig. 7, disponível em Ramanath et al. (2005). De forma que a informação da cor coletada no sensor nem sempre é aquela percebida pelo olho humano, assim, algumas vezes se trabalha com outros padrões de representação de cor, como YCbCr, XYZ, e outros como CieLab (PRATT, 2007), para obter estimativas mais precisas, com o aproveitamento de peculiaridades em cada padrão.

Vamos olhar brevemente aos filtros usados no sensor. A Figura 7 mostra um conjunto de amostras de sensibilidade de filtros. Note que os filtros têm sensibilidades que são diferente de zero, até mesmo fora da parte aceita como visível do espectro (400-700 nm) Este problema pode ser amenizado, como mencionado anteriormente, ao se aplicar um filtro bloqueador de infravermelho em conjunto com as lentes. Comparando as sensibilidades do observador padrão CIE, [...] com as sensibilidades do CFA, podemos antecipar que o espaço de cores da câmera será bem diferente do espaço de cores de um observador humano. Note também que há regiões de intercessão marcantes nas sensibilidades espectrais dos três canais da câmera, os quais, em conjunto com o *blurring*, reduz problemas com artefatos associados com *Demosaicing* na sequência do processo de formação da imagem. (RAMANATH et al., 2005)

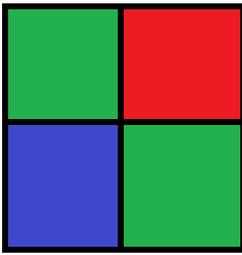


Figura 8: Bayer

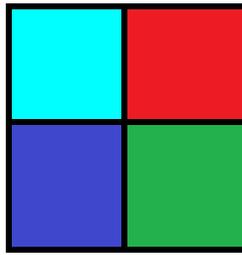


Figura 9: RGBE

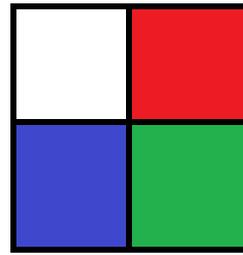


Figura 10: RGBW

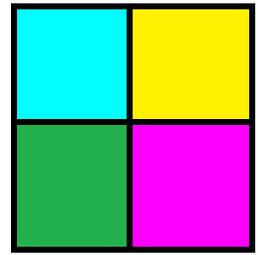


Figura 11: CYGM

2.2 ARRANJOS DE FILTROS DE COR - COLOR FILTER ARRAY (CFA)

Como já foi visto no capítulo anterior, o CFA é o que torna possível a captura de elementos de cor utilizando somente um sensor. Ele é composto por vários painéis que tem como finalidade filtrar uma faixa do espectro da luz que chega ao sensor, fornecendo assim a diferenciação de cores em cada pixel. Os padrões de CFA são estruturas que se repetem por todos os *pixels* da imagem, o que leva os dados a apresentarem um padrão que facilita a reconstrução da imagem com todos os canais completos. Há vários padrões diferentes existentes nas câmeras digitais, mas é predominante o uso do padrão Bayer, na Fig. 8, pela sua simplicidade, embora existam também outros padrões que buscam informações que o padrão Bayer ignora, como é o caso do padrão CYGM, na Fig. 11. Outros padrões tentam complementar os dados fornecidos pelo padrão Bayer com a substituição de um elemento deste CFA por outro, como é o caso do RGBE e RGBW, respectivamente nas Figura 10 e 9. Enfim, como foi apresentado, há muitos CFAs com diferentes especialidades (MENON; CALVAGNO, 2009), cuja qualidade depende em parte de características da imagem que se deseja capturar, e essa dependência não permite a eleição de um CFA ótimo para todas as imagens.

A influência do CFA pode ser vista de uma maneira diferente dos casos apresentados no início deste capítulo. O CFA é o componente que determina quais canais de cor são recebidos pelo sensor. Assim, a qualidade do sinal recebido é proporcional à semelhança da cor que se captura com a cor que é filtrada no CFA. De modo que a qualidade de determinado CFA em uma determinada imagem é dependente dessa semelhança. Assim, há a necessidade da montagem de uma grade de CFA capaz de funcionar bem em grande parte das possibilidades de imagens, pois não é viável substituir o CFA de uma câmera visto que o mesmo é inserido na construção do próprio sensor. E essa é uma das razões de haver diversos padrões diferentes de CFA. Sem entrar no mérito financeiro, há muita dificuldade em se determinar qual o melhor CFA, pois cada um apresenta vários pontos positivos, e em conjunto com algoritmos específicos para cada CFA, os seus desempenhos, verificados na qualidade das reconstruções, se tornam similares, como é mostrado no experimento deste trabalho, apresentado no capítulo 6.

Ao inserir o CFA no modelo de captura empregado neste trabalho, o operador \mathbf{H} na Eq. (3) se altera para que os dados capturados sejam os mesmos de uma captura real. Ou seja, ao utilizar o operador \mathbf{H} que produz os mesmos dados que uma captura real proveria, tem-se uma reprodução fiel do processo. Com isso, para se ter a versatilidade do trabalho com diversos CFAs diferentes é preciso que esse operador seja adaptável a qualquer modelo de CFA, e como a captura se resume a uma amostragem de elementos da imagem original, tem-se que o operador \mathbf{H} é uma matriz cujas posições onde são efetuadas as capturas são representadas por elementos unitários, e o restante da matriz é composta por elementos nulos, como pode ser visto na Eq. (4). Por exemplo, em uma linha da matriz do operador em que a captura corresponde a um pixel ciano (como se verifica nos padrões RGBE e CYGM), tanto a coluna correspondente ao pixel na posição do canal verde quanto na posição do canal azul apresentam o elemento unitário, e o restante da linha é composto por zeros. Isso se dá devido a filtragem exclusiva do elementos daquela posição específica, o que ignora qualquer interferência vinda de *pixels* vizinhos, por essa razão, os elementos de outras posições são anulados, assim como canais de cor que não conseguem atravessar o painel do filtro, que no exemplo se trata do canal vermelho.

A dificuldade de se comparar CFAs diferentes está no algoritmo empregado em cada um dos conjuntos de dados, que usualmente exploram características mais marcantes de cada conjunto de dados para obter resultados melhores, em outras palavras, o desempenho do algoritmo de reconstrução contribui para uma imagem de qualidade maior e o mesmo tem uma interdependência muito grande com o conjunto de dados, o qual depende do CFA.

Por essa razão, a qualidade de um CFA específico é difícil de ser determinada, uma vez que a aferência do desempenho do CFA considera somente o resultado final da estimativa. Não havendo ainda uma maneira de medir a qualidade de um CFA através dos dados que ele fornece somente, e sim uma medição da qualidade da estimativa calculada por um método de *Demosaicing* aplicado em um conjunto de dados daquele CFA, o qual não tem utilidade se o CFA for alterado. Dessa forma, ainda não há distinção entre quanto da qualidade total da estimativa foi por causa do CFA utilizado e quanto foi a contribuição do método empregado.

Com essa necessidade de distinção em mente, uma maneira de verificar a qualidade exclusiva dos dados é se utilizar de um processo reconstrutivo comum em CFAs diferentes. Um algoritmo flexível o bastante para trabalhar com quaisquer que sejam os dados oriundos de um CFA, e fornecer uma resposta aceitável, pois com isso será possível comparar CFAs, verificando a qualidade de cada um, e até mesmo sugerir um CFA mais adequado para imagens com características predominantes, por exemplo, um CFA que ressalte tons de azul em uma imagem de paisagem celeste.

Desse modo, este trabalho apresenta o devido algoritmo, que é descrito no capítulo 5, com a versatilidade de se trabalhar com diferentes CFAs, desde que a matriz de captura seja configurada para o mesmo.

3 MÉTODOS DE DEMOSAICING

Atualmente existem diversas maneiras de realizar a restauração dos componentes do *pixel* perdidos pela captura de imagens coloridas através do mosaico do CFA. Esses métodos lidam com o uso de filtros, álgebra linear e até mesmo processos estocásticos. A forma mais intuitiva de se estimar uma dessas características faltantes é a combinação linear entre vizinhos, chamada de interpolação linear, e em alguns casos obtém resultados aceitáveis, dependendo da aplicação. O problema desse método mais simples é a indiferença no tratamento dos dados de todas as regiões para determinar valores desconhecidos, áreas da imagem onde há bordas ou texturas com detalhes maiores são ignorados, como pode ser visto na Figura 11, o que inviabiliza tal procedimento em aplicações em que a qualidade e nitidez das bordas são essenciais.

Para corrigir a falta de nitidez das bordas deve-se pensar que outras informações que derivam dos dados capturados podem ser úteis na reconstrução. Por exemplo, ao verificar a existência de uma borda, há interesse em manter essa característica, ou seja, em caso de borda vertical ou horizontal, opta-se pela interpolação ao longo da direção da mesma, e não através da borda. Essa ideia foi explorada por muitos autores, como (LAROCHE; PRESCOTT, 1994), (HAMILTON; ADAMS, 1997), (SAITO; KOMATSU, 2008), (ZHANG; WU, 2005), alguns serão detalhados na sequência. Ou ainda, no caso de regiões com texturas bem características e relevantes em que é buscada uma solução que não distorça essas regiões, preservando a informação.

3.1 INTERPOLAÇÃO DIRECIONADA A BORDAS - LAROCHE, PRESCOTT

A princípio Laroche e Prescott (1994) consideraram fixo o CFA Bayer, e a partir dele sugeriram utilizar a diferença entre os elementos de ambos os lados de cada *pixel* para obter um limiar direcional. O conceito é utilizar a diferença entre *pixels* dispostos horizontal e verticalmente na interpolação da cor verde, com isso se obtém seus respectivos indicadores e realizar a comparação para verificar a direção onde a diferença é maior. A direção de maior diferença é a que será aplicada na interpolação do *pixel*, um esquemático do funcionamento do algoritmo

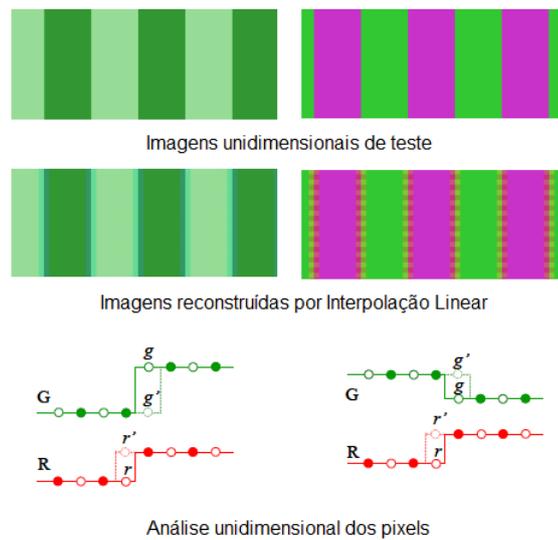


Figura 12: Análise unidimensional de bordas, em que no primeiro exemplo, os canais de cor alteram no mesmo sentido (ambos aumentam o seu valor) e, no segundo, os canais se alteram em direções diferentes (enquanto um cresce o outro decresce), tendo ambas as bordas uma sincronia inerente às imagens naturais como visto no trabalho de (ZHANG; WU, 2005). Observa-se que a captura nessa região crítica pertencente à borda causa, na interpolação linear, a suavização da borda, como visto nas imagens reconstruídas do exemplo, isso se dá pela interpolação linear considerar uma ponderação baseada somente nos valores de seus vizinhos e não em um contexto mais amplo, como a identificação da borda. Fonte: (SAITO; KOMATSU, 2008)

está disposto na Figura 13. Essa comparação tem o intuito de verificar a existência de bordas, uma vez que a interpolação ao longo da borda apresenta resultados melhores do que uma interpolação através da mesma.

Dessa forma, O funcionamento do algoritmo é limitado à disposição dos dados na configuração desejada, em outras palavras, ao uso do CFA de Bayer.

3.2 INTERPOLAÇÃO DIRECIONADA A BORDAS - HAMILTON, ADAMS

Com base na ideia do algoritmo de Laroche e Prescott (1994), Hamilton e Adams (1997) utilizam outra informação a respeito de imagens coloridas, a correção de canais de cor, para ajudar a identificar uma borda horizontal ou vertical. Por exemplo, supondo dados coletados em um padrão de CFA Bayer, para determinar a existência de uma borda em um canal de cor, o canal verde, o algoritmo utiliza informações contidas nos vizinhos do próprio canal verde e também de um outro canal, vermelho ou azul, dependendo da linha e coluna em que se estima o *pixel* em questão, como mostra a Figura 14. Com essa informação adicional o algoritmo percebe com mais facilidade a existência de bordas, o que garante a ele uma qualidade superior ao visto anteriormente por Laroche e Prescott (1994). Como o algoritmo requer a disposição de

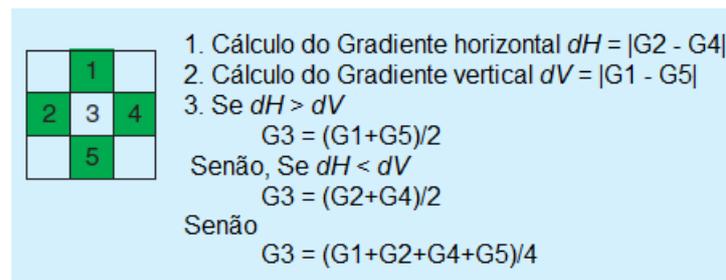


Figura 13: Esquemático empregado no processo de interpolação direcionada às bordas da imagens segundo proposto por (LAROCHE; PRESCOTT, 1994), e tem por princípio uma região da imagem em que se tenha todos os *pixels* vizinhos vertical e horizontalmente. O procedimento empregado é de se estabelecer uma comparação entre a diferença dos *pixels* horizontais com a diferença dos verticais com o intuito de perceber alguma direção com maior destaque que a outra para ser privilegiada e evitar o problema apresentado na interpolação linear de suavização de bordas. Fonte: (GUNTURK et al., 2005)

pixels ainda mais específica para o cálculo do indicador direcional, persiste a dependência com o filtro de Bayer, a qual é acompanhada de um desempenho melhor.

3.3 INTERPOLAÇÃO ADAPTATIVA (DLMMSE) - ZHANG, WU

Utilizando o sistema proposto por Hamilton e Adams (1997) de interpolação direcional mencionado anteriormente, Zhang e Wu (2005) elaboram uma adaptação do resultado, o princípio da abordagem deles é calcular um sinal diferente das informações obtidas na aquisição, o qual chamam de PDS (*Primary Difference Signal*), que é a diferença entre canais de cor. Ao apresentar estudos no domínio da frequência sobre o PDS de imagens, Zhang e Wu (2005) observaram a suavidade inerente a diversas imagens antes da captura simulada, e compararam com o resultado de uma variação da proposta de Hamilton e Adams (1997). A adaptação consiste nos mesmos cálculos de bordas horizontais e verticais, mas não há um limiar que determina se a borda é horizontal ou vertical, a variação que Zhang e Wu (2005) propõem gera duas imagens como resultado, uma delas com interpolações somente horizontais e a outra com verticais somente.

Na sequência o algoritmo proposto por Zhang e Wu (2005) realiza a análise dos espectros dos PDSs de cada uma das imagens resultado através de transformadas de Fourier (LATHI, 2007), as quais têm características de sinais passa-banda (ZHANG; WU, 2005). Com isso, o algoritmo deles aborda a probabilidade com base no erro quadrático médio (MSE) entre as estimativas direcionais existentes e a imagem original que se desconhece, em que ele calcula o erro da estimativa horizontal e vertical em relação a uma imagem ideal, e se aplica uma compensação para corrigir esse erro no domínio da frequência.

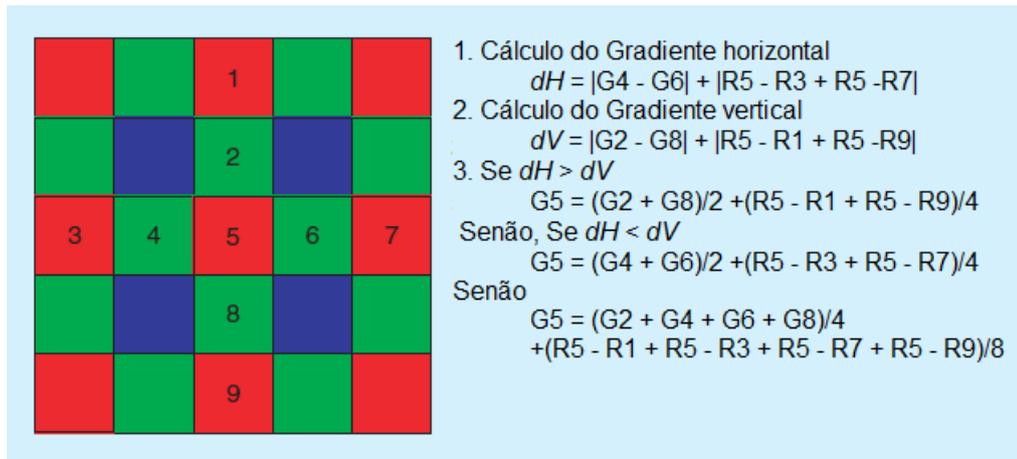


Figura 14: A figura mostra o esquemático que é empregado no processo de interpolação direcionada às bordas da imagens segundo proposto por (HAMILTON; ADAMS, 1997), e tem por princípio uma região da imagem em que se tenha todos os oito *pixels* vizinhos horizontais e verticais, com 2 *pixels* de distância do *pixel* que se deseja estimar, o *pixel* central. O procedimento, neste caso, também é de se estabelecer uma comparação entre a diferença dos *pixels* horizontais com a diferença dos verticais com o intuito de perceber alguma direção com maior destaque, porém o algoritmo também leva em conta informações contidas no canal de cor disponível, vermelho ou azul de acordo com a linha e coluna em que se encontra o valor estimado, para identificar a existência da borda. Fonte: (GUNTURK et al., 2005)

Depois disso, Zhang e Wu (2005) procuram a melhor proporção entre a estimativa horizontal e vertical, que é a estimativa que apresenta menor variância dos PDSs e o erro estimado dos mesmos, sendo utilizada uma ponderação para suavizar diferenças abruptas entre as estimativas do PDS de cada direção, eles chamam este procedimento de *Directional Linear Minimum Mean Square Error DLMMSE*. Com isso, o algoritmo apresenta uma proposta com bastante eficiência, conforme será mostrado no capítulo 6, para reconstruir os dados através do *Demosaicing*, porém novamente é uma abordagem que requer que os dados sejam fornecidos conforme o padrão de CFA de Bayer, embora seja possível adaptar o funcionamento do algoritmo para lidar com CFAs diferentes. Um esquemático que resume as etapas do algoritmo de Zhang e Wu (2005) pode ser visto na Figura 15.

3.4 INTERPOLAÇÃO ADAPTATIVA (LPA-ICI) - PALIY, DMITRIY

O algoritmo proposto por Paliy et al. (2007) tem como fundamento a formação de imagens interpoladas horizontal e verticalmente, com uma regra de interpolação da mesma maneira que Hamilton e Adams (1997) calcula os limiares direcionais. Com imagens completas estimadas com interpolações direcionais, Paliy et al. (2007) calculam a diferença de canal de cor, similar ao PDS do método anterior (ZHANG; WU, 2005), para as respectivas direções interpolativas. Por fim Paliy et al. (2007) assumem que a diferença entre os sinais PDS obtidos com

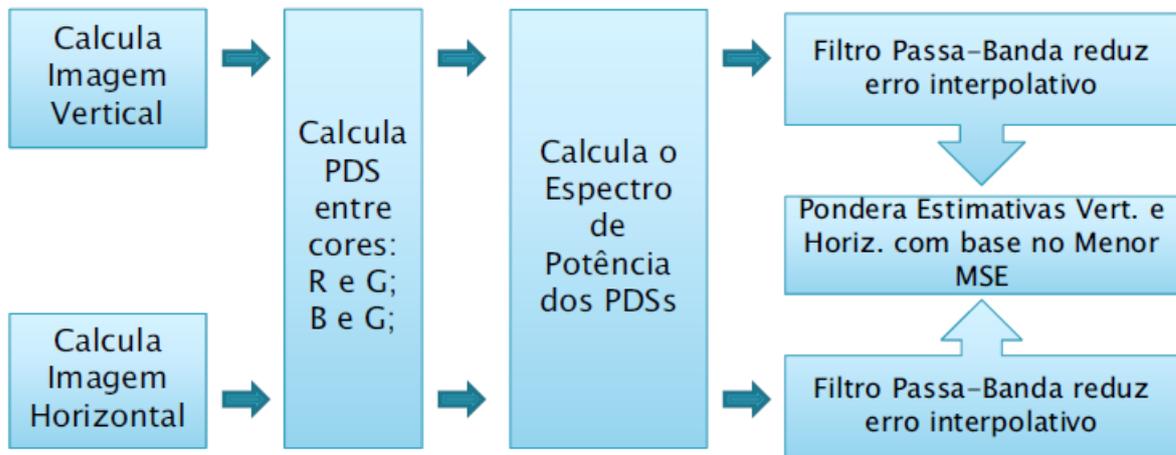


Figura 15: Esquemático empregado no processo de interpolação adaptativa proposto por Zhang e Wu (2005), nele mostra-se as etapas pelas quais a solução desses autores passa para atingir o resultado final. Inicialmente eles consideram que os dados têm a estrutura de captura de CFA Bayer, assim eles conseguem realizar interpolações lineares na cor verde e o fazem unidirecionalmente, tendo duas soluções parciais, a horizontal e a vertical. São calculados os sinais de PDS de cada um e é feita a análise de espectro de potência deles, aplicando correções na faixa do sinal em que os autores acreditam que esteja a diferença entra a imagem original e as estimativas parciais. Em seguida, retornam os sinais para o domínio do tempo e fazem uma ponderação entre a estimativas horizontais e verticais para os elementos faltantes dos *pixels*. Fonte: O Autor

as etapas anteriores e a imagem que desejam reconstruir são erros atribuídos às interpolações direcionais, que serão tratados com técnicas de .

Na sequência, Paliy et al. (2007) calculam um filtro através de aproximação por polinômios locais (LPA), que no caso do algoritmo proposto acabou sendo formado por *kernels* polinomiais. O filtro é composta pela ponderação entre *kernels* de ordem zero e de primeira ordem, embora o mesmo ainda dependa da variável que identifica a dimensão dos *kernels*. Nesse segundo momento entra a interseção de intervalos de confiança (*Intersection of Confidence Intervals* - ICI) com a função de limitar a dimensão dos *kernels* encontrados para o filtro, e tornar o mesmo mais tangível. A função desse filtro é trabalhar em um espaço diferente dos dados onde as conclusões e conceitos apresentados na sequência são válidos e contribuem para uma melhor reconstrução. Um esquemático resumido dos processos do algoritmo de Paliy et al. (2007) está disposto na Figura 16.

Em seguida, o algoritmo de Paliy et al. (2007) utiliza o desvio padrão dos sinais verticais e horizontais filtrados como pesos para o cálculo de um PDS composto pela combinação de ambas. Com o PDS final calculado, o algoritmo forma todos os valores desconhecidos do canal verde como a soma do valor conhecido da posição específica com o valor do PDS correspondente. Dessa maneira os autores conseguem combinar as características da interpolação direcional ponderada inserida através da filtragem do PDS para o cálculo do sinal verde.

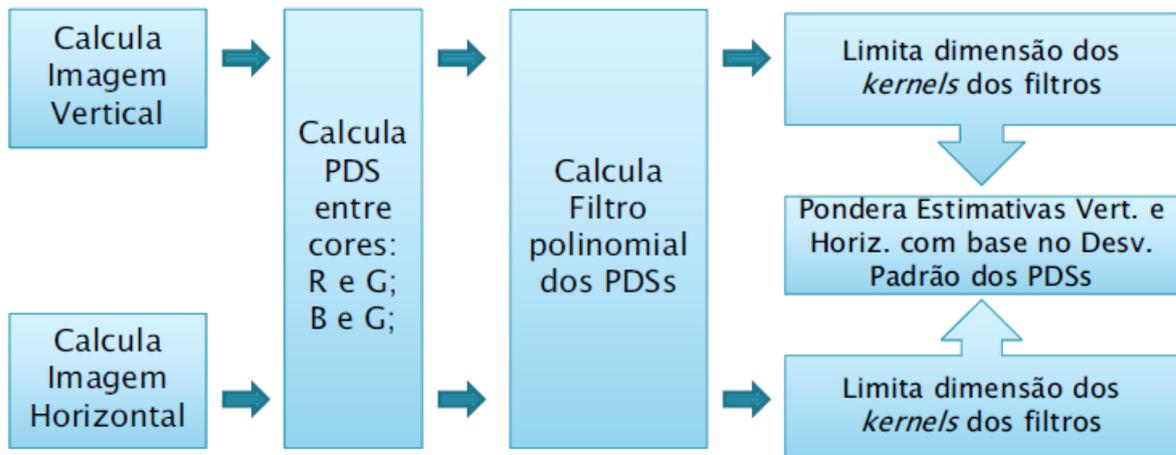


Figura 16: Esquemático empregado no processo de interpolação adaptativa proposto por Paliy et al. (2007), nele mostra-se as etapas pelas quais a solução desses autores passa para atingir o resultado final. Inicialmente eles consideram que os dados têm a estrutura de captura de CFA Bayer, assim eles conseguem realizar interpolações lineares na cor verde e o fazem unidirecionalmente, tendo duas soluções parciais, a horizontal e a vertical. São calculados os sinais de PDS de cada um e é estimado um filtro polinomial específico para aquele conjunto de dados, em que se limita a dimensão do filtro através de *kernels*. A aplicação do filtro limitado pelos *kernels* em cada um dos sinais PDS gera estimativas horizontais e verticais, que são ponderadas para a estimativa final do algoritmos de Paliy et al. (2007) . Fonte: O Autor

A formação dos canais vermelho e azul consiste na aplicação de filtros diferentes, dependendo da linha e coluna do *pixel* conforme a disposição do padrão de CFA Bayer. E de forma similar ao cálculo do sinal verde, as estimativas são formadas pelos dados providos pela captura somados com o PDS filtrado pelo conjunto do LPA-ICI descrito para o canal verde, e em seguida o filtro específico, da cor vermelha ou azul dependendo da cor que está sendo calculada.

Com isso, o algoritmo apresentado por Paliy et al. (2007) almeja atingir reconstruções ainda mais precisas do que os outros métodos revisados, visto que, novamente o cálculo do PDS e a implementação do princípio adaptado de Hamilton e Adams (1997) força o CFA a apresentar a configuração de Bayer. Embora seja possível a adaptação para outros CFA diferentes para tornar o algoritmo flexível, esse recurso requer uma reestruturação dos três filtros apresentados no trabalho de Paliy et al. (2007).

4 PROBLEMAS INVERSOS

Problemas inversos são um conjunto de problemas cuja abordagem solutiva é baseada na premissa de que existe um processo, uma transformação que alterou a informação desejada nos dados disponíveis do trabalho. Tal situação é mostrada na Equação (5), na qual a informação mencionada é representada por \mathbf{x} a qual forma os dados \mathbf{b} através da transformação \mathbf{A} . Assim, o conceito do problema inverso consiste em encontrar a transformação inversa \mathbf{A}^{-1} que aplicada aos dados \mathbf{b} fornece a informação desejada \mathbf{x} , como mostrado na Equação (6).

$$\mathbf{b} = \mathbf{A}\mathbf{x} \quad (5)$$

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{b} \quad (6)$$

Um ponto que torna a inversão \mathbf{A}^{-1} mais complexa é que a mesma nem sempre existe para todos os problemas, isso ocorre quando \mathbf{A} é singular, e isso pode ser verificado com as condições de Hadamard (1923). As mesmas funcionam como limites que determinam se um problema é bem-posto ou mal-posto, a verificação de quaisquer das condições de Hadamard implicam na mal-posição do problema que significa que não existe uma inversa direta \mathbf{A}^{-1} .

- Primeira condição - Não existe solução exata.
- Segunda condição - Existem infinitas soluções para o problema.
- Terceira condição - A solução é instável.(HADAMARD, 1923)

A verificação de alguma das condições de Hadamard não implica que o problema não pode ser resolvido, mas que a sua solução será mais complexa. No caso do problema tratado neste trabalho, o *Demosaiicing* apresenta a segunda condição de Hadamard devido à perda de informações no processo de captura, e para recuperar essa informação o algoritmo tem que estimar um valor mais provável entre todas as infinitas possíveis soluções. Essa incerteza da

estimativa correta pode ser reduzida com a utilização de informações a respeito de imagens semelhantes, de comportamentos comuns observados usualmente. A terminologia empregada para definir essa informação adicional, não explícita nos dados obtidos, é chamada de *Prior* por se tratar de um conhecimento disponível a priori da aquisição dos dados.

4.1 PRIOR

Prior é a informação conhecida a priori da solução, que permite inserir uma tendência na estimativa, com o objetivo de reduzir a quantidade de possibilidades de solução. Como discutido anteriormente e observado no trabalho de Zhang e Wu (2005), há forte correlação entre canais de cor, vide Figura 7, a qual é explorada no algoritmo proposto neste trabalho. Na proposta, o *Prior* inserido tem a função de provocar a correlação entre os canais da estimativa, levando a imagem-solução a apresentar tal característica.

$$\hat{\mathbf{f}} = \arg \min_f \|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2 + \lambda \|\mathbf{P}\mathbf{f}\|_1 \quad (7)$$

Esta inserção de comportamento assume a forma descrita na Equação (7), em que há uma proporção definida pelo parâmetro λ que pondera a influência da inserção da correlação de canal de cor em relação ao termo de fidelidade dos dados. Em outras palavras, a estimativa é formada pela combinação de duas características: a fidelidade dos dados, que é manter a estimativa gerada condizente com o modelo de captura empregado, dado por $\|\mathbf{g} - \mathbf{H}\mathbf{f}\|_2^2$, onde $\|\mathbf{x}\|_2^2 = \sum |x_i|^2$ é a norma ℓ_2 . No caso de uma captura que não considera o efeito do ruído, o valor mínimo para esse termo não é outro senão zero, pois não havendo distorções que alterem os valores iniciais em uma estimativa, a mesma apresentará a norma mínima.

Novamente, recorda-se que *Demosaicing* sofre da segunda condição de Hadamard (HADAMARD, 1923), ou seja há infinitas soluções em que a norma ℓ_2 é a mínima, por essa razão, a caracterização do sistema de captura sozinha é insuficiente para estimar uma imagem definitiva como solução para o problema. Por esse motivo, é necessária a segunda característica, denotada por $\|\mathbf{P}\mathbf{f}\|_1$ na Equação (7), que promove dentre as infinitas soluções mínimas para a primeira característica a mais adequada conforme o conhecimento a priori do problema.

Como destacado, a característica observada, que é utilizada como o *Prior* do algoritmo, é a alta correlação dos canais de cor de imagens, o que significa que o PDS de dois canais de cor apresenta o aspecto suave como mostrado na Figura 17. Essa suavidade implica em valores próximos a zero na diferença finita, como mostra a Figura 18, que representa a derivada parcial para sinais discretos. Através do levantamento do histograma das diferenças finitas, vide Figura

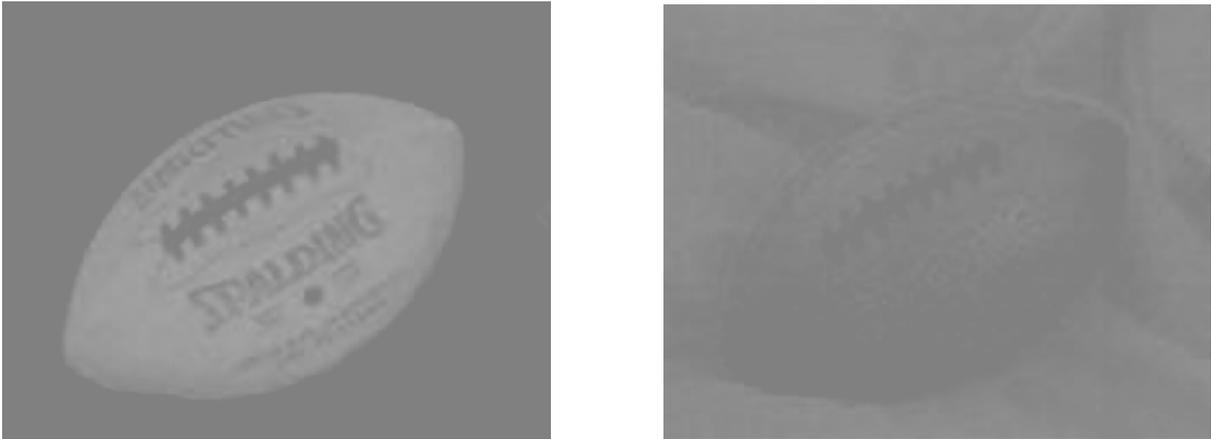


Figura 17: Espaço formado pela diferença de cor, R-G e B-G respectivamente à esquerda e à direita.

19, é possível perceber a presença de muitos elementos ao redor do zero, o que justifica a utilização desse conceito como *Prior* do algoritmo.

Uma das características de sinais suaves é que a derivada de primeira ordem deles apresenta valores próximos de zero para regiões uniformes, e para aplicar o conceito de derivação em primeira ordem de sinais discretos é utilizado o operador de diferenças finitas aplicado em cada linha e coluna do sinal bidimensional (BARRETT; MYERS, 2004). O *Prior*, representado por $\|\mathbf{P}\mathbf{f}\|_1$, na qual a norma ℓ_1 representa a soma dos valores absolutos dos elementos do vetor, descrita pela Equação (8), ao ser minimizado busca então soluções com poucos elementos em sua composição.

$$\|\mathbf{x}\|_1 = \sum |x_i| \quad (8)$$

Como já mencionado, ambas as características têm pesos diferentes, determinados pelo parâmetro λ , para encontrar uma solução mais adequada para o problema, assim λ também representa a confiança que se tem dos dados obtidos com a captura. Para situações em que o ruído é muito intenso durante a captura, o termo de fidelidade dos dados torna-se mais questionável quanto a veracidade, o que permite um λ maior para compensar essa questão. Em uma situação de ruído desprezível, admite-se o menor λ possível para que a tendência que o prior insere não desvie a solução para uma estimativa que destoe do termo de fidelidade dos dados.

A diferença entre as normas mostradas, ℓ_1 e ℓ_2 , não se restringe ao cálculo das mesmas pois a função de minimização que rege o problema apresenta características de ambas devido ao modelo empregado ser uma soma das duas normas ponderadas. O método usado para che-

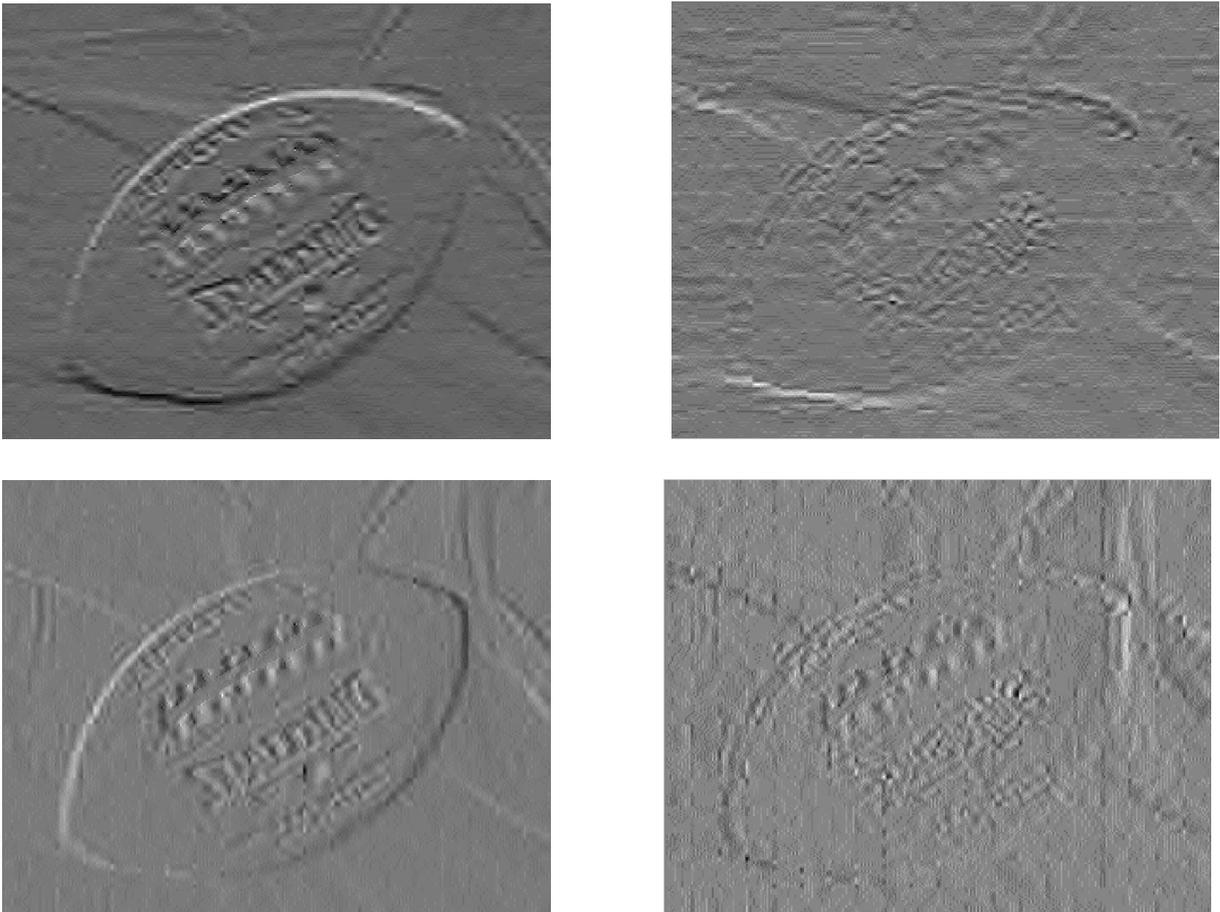


Figura 18: Configuração do espaço formado pela diferença finita do PDS, sendo as imagens à esquerda o PDS entre os canais vermelho e verde, enquanto que as imagens à direita retratam o PDS entre os canais azul e verde, sendo diferença finita vertical das imagens acima e a horizontal abaixo.

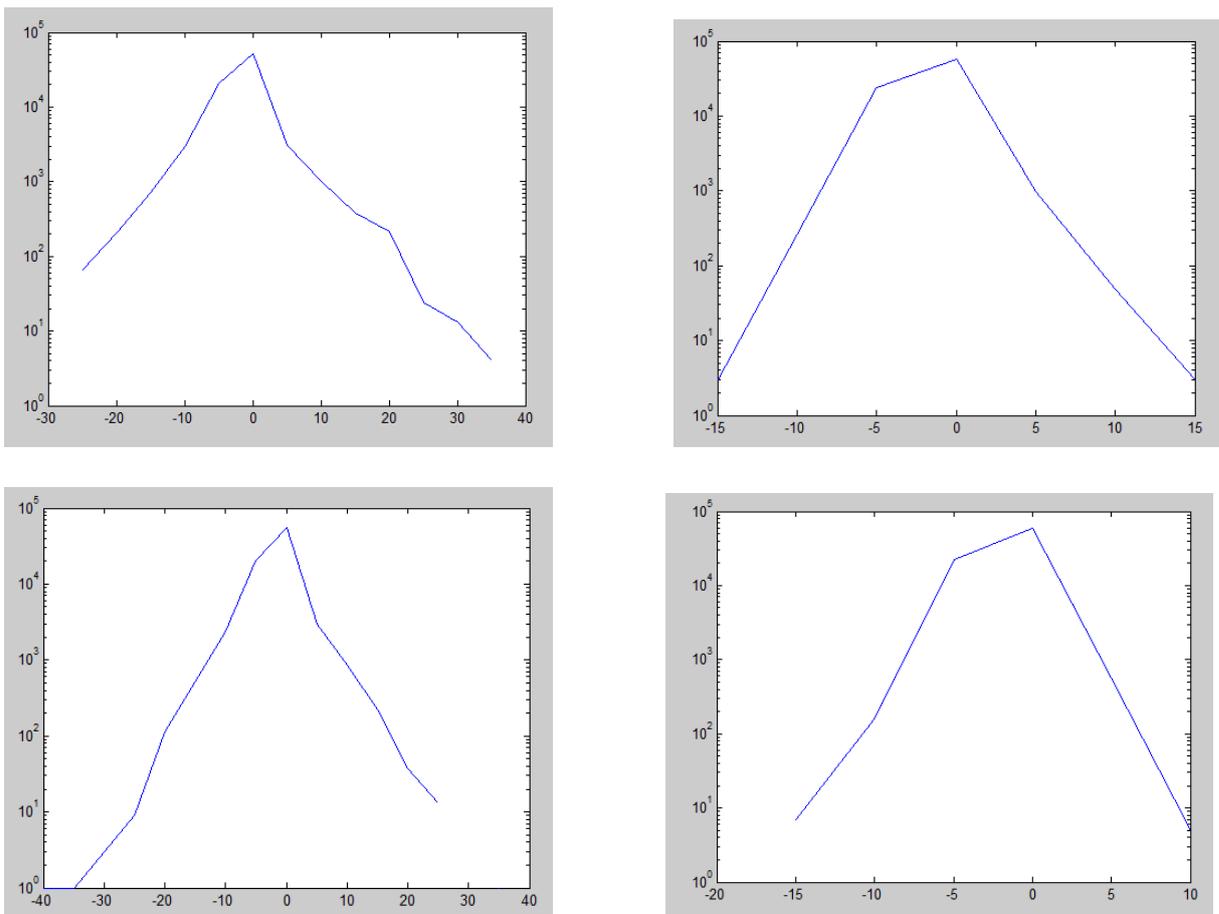


Figura 19: Histogramas das diferenças finitas verticais e horizontais (acima e abaixo respectivamente) dos planos formados pela diferença das cores verde e vermelho à esquerda, e verde e azul à direita, em escala logarítmica.

gar à solução mínima do problema deve ser adaptado para minimizar tanto problemas de uma norma quanto da outra, como o IRLS. Neste método o mínimo da norma ℓ_1 é calculado da mesma maneira que a norma ℓ_2 porém há uma ponderação representado na Equação (9) pela transformação \mathbf{W} , que é uma matriz diagonal que na proposta apresentada nesta dissertação tem seus elementos descritos pela Equação (10), os quais são atualizados a cada conjunto de iterações.

$$\mathbf{A} = \mathbf{H}^T \mathbf{H} + \mathbf{P}^T \mathbf{W} \mathbf{P} \quad (9)$$

$$w_i = \frac{1}{\|[\mathbf{P}\mathbf{f}]_i\|_2 + \varepsilon} \quad (10)$$

Em que \mathbf{A} é uma matriz quadrada, representada na Equação (5), \mathbf{H} é a matriz de captura conforme o CFA empregado, \mathbf{P} é o prior do sistema, e por fim \mathbf{W} é uma matriz diagonal responsável pela minimização de norma ℓ_1 . Cada elemento diagonal de \mathbf{W} forma um peso segundo a Equação (10), para reconstrução através da solução de quadrados mínimos iterativamente reponderados (*Iteratively Reweighted Least Squares* - IRLS. Onde se tem que cada elemento w_i da diagonal de \mathbf{W} é inversamente proporcional ao elemento que será ponderado, $\mathbf{P}\mathbf{f}$, em que a fração apresenta o elemento ε como parâmetro para evitar a divisão por zero.

O modelo matricial empregado no trabalho, descrito detalhadamente no segundo capítulo, garante à solução de problema inverso uma capacidade de adaptação conforme as condições de captura empregadas (CFA, tempo de exposição, resolução). Assim, com as devidas adaptações na matriz de captura é possível se simular aquisição de dados de diversos CFAs diferentes, que é a proposta do presente trabalho.

A flexibilidade do modelo de problema inverso não se limita somente ao CFA empregado, há também o uso de um prior adequado, o qual pode contemplar diversos aspectos da imagem esperada (regiões de suavidade, bordas definidas, correlação de canais de cor). Essa propriedade provê ainda mais possibilidades de lidar com o problema de *Demosaicing*. Essa flexibilidade também é verificada no algoritmo pesquisado neste trabalho. A partir do momento em que a captura é simulada dentro do algoritmo, se estima a matriz de transformação que é responsável por fornecer os dados como se fosse uma captura natural, com o CFA escolhido e os parâmetros desejados, a diferença é que a imagem é digital. Com a matriz responsável por gerar os dados do CFA, o algoritmo encontra a matriz que faz a operação inversa para gerar os resultados finais. Ou seja, com o algoritmo proposto, há a necessidade de somente reproduzir a captura dos dados do CFA em uma matriz, com isso o algoritmo tem a capacidade de formar

uma imagem reconstruída possível e de qualidade boa.

4.2 *EXTENDED TOTAL VARIATION* - (??)

Existem na literatura métodos de *Demosaicing* que empregam o conceito de problema inverso, é o caso do trabalho descrito em (SAITO; KOMATSU, 2008). Nele, os autores utilizam em uma aquisição simulada com o padrão Bayer, e o prior estudado pelos autores destaca a suavidade de quatro planos de cor formados pela soma dos canais verde e vermelho, verde e azul, e pela diferença de verde e vermelho, verde e azul, respectivamente, com o intuito de identificar bordas e optar pela borda que apresenta a menor variação total. O conceito de variação total (*Total Variation* - TV) implica na verificação de borda, sendo ela positiva ou negativa em ambos os canais de cor, situação na qual as diferenças desses canais apresentam a variação total mínima, ou se a borda é positiva em um canal e negativa em outro, situação na qual a soma dos canais apresenta a variação mínima.

[...] em adição à regularização de cada sinal de cor primária, nós introduzimos a regularização TV de diferenças de cores, $\mathbf{G} - \mathbf{R}$ e $\mathbf{G} - \mathbf{B}$, e somas de cores, $\mathbf{G} + \mathbf{R}$ e $\mathbf{G} + \mathbf{B}$, [...] que conjuntamente interpola as três cores primárias e consegue interpolações de cor precisas próximas a bordas de cor definidas.(SAITO; KOMATSU, 2008)

As características descritas do *Prior* de Saito e Komatsu (2008) serviram como base inspiradora para a proposta que será apresentada no capítulo 5. E assim como os problemas inversos que apresentam a inversão muito custosa computacionalmente, o algoritmo destes autores recorre a dividir o cálculo total de inversão em várias etapas menores e mais simples. Essas etapas são as iterações que levam a um resultado intermediário, entre os dados e a solução exata, que são atingidas com maior velocidade que a inversão direta e que se sujeita a admitir que existe um resultado intermediário de qualidade, semelhanças com a imagem original, aceitável para a aplicação.

4.3 ALGORITMO ITERATIVO

Nas situações em que os problemas recaem nas condições de Hadamard (1923), a inversão direta leva a situações extremas, como a amplificação do ruído. (BOVIK, 2000). Além disso, visto que o custo computacional de uma inversão de matriz é proporcional às dimensões da imagem, é preferencial que se obtenha a solução parcial, através de métodos iterativos, à inversão direta por razões de tempo de processamento. Assim, é necessário que seja estabelecido um critério de parada do algoritmo iterativo, um termo que determine que o resultado já

está bom o suficiente e que o algoritmo já pode ser encerrado. Existem muitos critérios que pode ser empregados, como um limiar da norma da diferença entre duas iterações consecutivas, a chegada ao mínimo da função custo, um limite máximo para o número de iterações, o que determina a melhor escolha do critério de parada é a aplicação.

Os algoritmos iterativos dispõe de uma gama de recursos que podem ser explorados para atingir o objetivo, que é o mínimo de uma função chamada de função custo, que na proposta é regida pela Equação (7). Apesar das diversas possibilidades, o procedimento empregado normalmente se resume a determinar uma direção de minimização, frequentemente envolvendo o gradiente, e o passo nessa direção, que se trata do deslocamento no espaço da função custo na direção de minimização. Por se tratar de um processo iterativo, após um passo de minimização o algoritmo calcula uma nova direção e na sequência o próximo passo. Dentre os algoritmos mais comuns há a utilização passo fixo (*Successive Approximation* - SA), passo que leva o sistema para o valor mínimo da direção atual (*Steepest Descent* - SD), e o passo que leva para o valor mínimo de uma direção conjugada, em que a direção é o gradiente da função custo vista de uma posição mais favorável à minimização, em que cada iteração minimize uma variável por vez do sistema (Gradiente Conjugado, CG). Este último apresenta grande eficiência na minimização e seu funcionamento segue a Equação (11), em que cada iteração resulta em um $\hat{\mathbf{f}}$ mais próximo da estimativa desejada que vai adequar a matriz de pesos $\mathbf{W}_{\mathbf{f}_k}$ para a forma que $\hat{\mathbf{f}}$ adquire.

$$\hat{\mathbf{f}}_{k+1} = (\mathbf{H}^T \mathbf{H} + \mathbf{P} \mathbf{W}_{\mathbf{f}_k} \mathbf{P})^{-1} \mathbf{H}^T \mathbf{g} \quad (11)$$

No trabalho proposto, a minimização iterativa da Equação (7) requer a solução de problemas ℓ_2 - ℓ_1 , e o IRLS é uma boa alternativa para isso. O IRLS consiste em tratar uma função de norma ℓ_1 como se fosse uma função de norma ℓ_2 ponderada, que na equação (11) se trata da matriz de pesos $\mathbf{W}_{\mathbf{f}_k}$, ela é atualizada a cada conjunto de iterações de minimização (SA, SD ou CG) estabelecido como parâmetro do algoritmo de IRLS.

[...]Nós nos concentramos em algoritmos de quadrados mínimos iterativamente reponderados por serem versáteis em acomodar múltiplos critérios de regularização convexos e não-convexos simultaneamente. O algoritmo IRLS é uma técnica simples que realiza a tarefa de minimização resolvendo vários sistemas lineares repetitivamente: o ponto chave é, a cada iteração i , a matriz Hessiana associada, $\mathbf{A}_{(i)}$, depende da iteração anterior o que o torna em geral um algoritmo não-linear. Entretanto, para problemas mal-postos, $\mathbf{A}_{(i)}$ pode não ser bem-condicionada pela própria natureza não suave de critérios de regularização que promovem a esparsidade. Nesses casos, Soluções iterativas como CG apresentar taxas de convergência muito lentas. (RAMANI; FESSLER, 2010)

Como se utiliza o IRLS para inserir a minimização de norma ℓ_1 na função custo, o que

é necessário é o uso CG para oferecer o valor mínimo de cada iteração mais eficientemente, o que resulta no IRLS-CG.

Por apresentar uma solução rápida se comparado com os outros métodos apresentados, SA e SD, o gradiente conjugado foi utilizado na proposta deste trabalho, como será apresentado no capítulo 5. O funcionamento mais detalhado do gradiente conjugado, com cálculo da direção de minimização, gradiente da função custo e passo mínimo, respectivamente \mathbf{d}_k , δ_k e \mathbf{p}_k , segue as seguintes etapas:

- Configurar os parâmetros iniciais: $\hat{\mathbf{f}}_0$, δ_0 e \mathbf{d}_0
- Repetir até atingir o critério de parada:
 - Calcular o passo: \mathbf{p}_k
 - Atualizar estimativa: $\hat{\mathbf{f}}_{k+1} = \hat{\mathbf{f}}_k + \mathbf{d}_k \mathbf{p}_k$
 - Calcular o gradiente: δ_{k+1}
 - Atualizar direção conjugada: $\mathbf{d}_{k+1} = \delta_{k+1} + \frac{\|\delta_{k+1}\|_2^2}{\|\delta_k\|_2^2} \mathbf{d}_k$

Assim, o algoritmo apresenta estimativas precisas com base no *Prior* de norma ℓ_1 e velozes com a utilização do CG, mas ainda é necessário definir até que ponto é preciso recalculá-la a estimativa. O critério de parada é muito importante para o algoritmo nesse sentido, pois, ele fornece e é responsável por limitar a quantidade de iterações realizadas, de modo que um critério muito baixo pode prover estimativas mais rápidas porém de qualidade inferior, e critérios muito elevados garantem a qualidade mas levam conseqüentemente mais tempo. De modo que um critério que é normalmente utilizado é uma tolerância, um limiar que é comparado com a magnitude de toda a variação que se dá de uma estimativa para a seguinte, em que, se a magnitude for maior que a tolerância, o algoritmo ainda está calculando estimativas novas. Caso contrário, a diferença entre as iterações é tão pequena que o algoritmo já pode assumir que a estimativa apresentada é a mínima.

5 PROPOSTA

Este trabalho apresenta uma proposta de algoritmo de *Demosaicing* utilizando um novo *prior*, desenvolvido com o objetivo de produzir resultados a nível do estado da arte através de abordagem de problemas inversos. Essa abordagem provê flexibilidade ao algoritmo permitindo o trabalho com diversos CFA diferentes sem perder a qualidade de reconstrução.

O algoritmo tem como base a estrutura de um problema inverso onde se tem por objetivo encontrar a imagem que originou os dados disponíveis, como indicado na equação (3). Juntamente com essa restrição, a de solução de imagem capaz de originar os dados, se faz necessário o emprego de uma função que represente algum conhecimento do problema ou mesmo uma tendência da solução desejada. Esse conhecimento é vinculado à função geradora dos dados, como visto na equação (7), com isso o problema se torna uma minimização da função custo do modelo, que é a minimização de duas funções ponderadas pelo parâmetro λ .

5.1 *PRIOR* PROPOSTO

O *Prior* empregado, como visto anteriormente, também apresenta componentes específicos para o problema de *Demosaicing*, como o emprego da diferença finita aplicada no espaço de cor formado pela diferença das cores verde e vermelho, e também das cores verde e azul, como visto na Figura 18. A utilização desses espaços de cor prioriza a busca de uma solução com alto teor de correlação apresentada pelo canal de cor verde com seus canais vizinhos, conforme apresentado na Figura 19. Isso é de fato observado em imagens naturais, como visto no capítulo 4, e provoca, entre outros fenômenos, a sincronia de borda entre os canais de cor.

Outra característica importante, dessa vez referente à imagem fora das regiões de bordas, é a suavidade observada. A suavidade espacial é atingida pela diferença finita aplicada a somente um canal de cor ou a uma combinação (soma) de canais disponíveis, dependendo da característica que se deseja explorar.

Em ambas as características apresentadas se verifica o uso do operador de diferença finita, que é a versão discreta da operação de derivada. O mesmo é o resultado de uma diferença de dois elementos do mesmo plano em que ambos são vizinhos, de modo que esta relação de vizinhança é mantida em todas as posições do plano. Por exemplo, diferença finita horizontal é uma operação aplicada a todas as linhas de uma cor, em que o resultado é a diferença do elemento com o seu vizinho da esquerda, do mesmo modo que a diferença finita vertical é o resultado da diferença do elemento com o seu vizinho superior.

Dessa maneira se tem na Equação (12) a concatenação das duas direções do operador de diferenças finitas, e seu uso em conjunto com a norma ℓ_1 implica na minimização para uma solução com elementos nulos ou próximos de zero, como verificado nos histogramas apresentados na Figura 19.

$$\mathbf{D} = \begin{bmatrix} \mathbf{D}_H \\ \mathbf{D}_V \end{bmatrix} \quad (12)$$

5.1.1 PRIOR CORRELATIVO - \mathbf{P}_C

Prior que busca a minimização do espaço composto pela diferença finita da diferença entre as cores da imagem, de forma que o uso do padrão de representação de cor RGB requer a implementação de dois componentes. Um deles para correlacionar a cor verde à cor vermelha, e outro para a verde e a azul. Assim, se tem que o *Prior* Correlativo segue a Equação (13), com \mathbf{f}_i representando a cor da imagem para $i = R, G, B$.

Percebe-se na Equação (13) a utilização da norma ℓ_1 o que implica na busca de uma solução com poucos elementos não-nulos, também conhecida por solução esparsa.

$$P_C = \|\mathbf{D}(\mathbf{f}_G - \mathbf{f}_R)\|_1 + \|\mathbf{D}(\mathbf{f}_G - \mathbf{f}_B)\|_1 \quad (13)$$

Por levar em consideração elementos de duas cores ao mesmo tempo, é uma solução que busca dar maior destaque a bordas encontradas na imagem, através da sincronia da mesma para evitar o problema mostrado anteriormente na Figura 3.

5.1.2 PRIOR ESPACIAL - \mathbf{P}_E

Este *Prior*, difere do anterior ao propor características suaves na imagem que são as regiões sem elementos de borda. Uma vez que a captura através do CFA fornece informações

verdadeiras de alguns elementos de acordo com o padrão empregado, o objetivo é usá-los como referência para os seus vizinhos mais próximos.

Com o problema da suavização indesejada das bordas solucionado pelo *Prior* Correlativo, é interessante que as outras regiões apresentem este aspecto para dar à estimativa uma feição mais natural. Essa característica pode ser adquirida com a minimização da diferença finita da cor verde, ou da luminância, ou até mesmo de uma combinação de ambas. Essas três opções foram exploradas para verificar se a qualidade de uma delas prevalece sobre as outras. Dessa forma foram estabelecidos os três *Priors* espaciais descritos nas Equação (14), (15) e (16), os quais foram utilizados nos experimentos que serão descritos no próximo capítulo.

$$P_{E_1} = \|\mathbf{Df}_R\|_1 \quad (14)$$

$$P_{E_2} = \|\mathbf{Df}_R + \mathbf{Df}_G + \mathbf{Df}_B\|_1 \quad (15)$$

$$P_{E_3} = \|\mathbf{Df}_R + 2\mathbf{Df}_G + \mathbf{Df}_B\|_1 \quad (16)$$

5.1.3 PROPORÇÃO ENTRE \mathbf{P}_C E \mathbf{P}_E

Devido a peculiaridades presentes em cada imagem, é indagada a utilização de uma preferência por um *Prior* ou outro para se atingir estimativas mais próximas da realidade. Dessa maneira, em imagens astronômicas, em que há alguns elementos mais claros que outros e que a suavidade é uma característica marcante, por exemplo, é preferível o preavalecimento do *Prior* Espacial, enquanto que a imagem de um vitral, onde a presença de bordas com frequentes mudanças de cor é notável, a preferência seria mais voltada para o *Prior* Correlativo.

Por esse motivo, sugere-se a utilização de um peso, representado por ω , responsável por essa proporção, de modo que o *Prior* é descrito pela Equação (17).

$$P = P_C + \omega P_{E_i} \quad (17)$$

Embora a proporção proposta tenha o objetivo de prover o melhor resultado para cada conjunto de dados, o cálculo de tal parâmetro ainda está em seus passos iniciais, sendo sugerido como estudos futuros.

A minimização da norma ℓ_1 dos espaços da diferenças finitas busca soluções esparsas

para o espaço mencionado, o que no espaço da imagem resulta em características suaves, tanto no plano de diferença de canais de cor, o que provê sincronia de bordas de objetos, quanto para o plano da luminância, que fornece suavidade local para pixels vizinhos.

No trabalho proposto é utilizado o algoritmo IRLS-CG de minimização por aproximar a função de norma ℓ_1 por uma de norma ℓ_2 através de ponderação aplicada na Equação (9). O mecanismo empregado no trabalho conta com duas etapas, o algoritmo atualiza a matriz de pesos e na sequência ele realiza um conjunto de iterações do gradiente conjugado (CG), atingindo um máximo de até 100 iterações. Em outras palavras, a matriz de ponderação \mathbf{W} na Equação (9) é atualizada depois um conjunto de iterações do CG são efetuadas até a estimativa convergir ou até uma quantidade máxima de 100 iterações.

O objetivo deste recurso é prover estabilidade para a minimização sem comprometer a velocidade, visto que as primeiras iterações do CG apresentam comportamento instável, devido aos diversos parâmetros configurados para um bom funcionamento em uma abrangência maior de imagens diferentes com o CFA especificado, e não otimizados para uma imagem específica.

Muitas vezes a inversão se torna muito custosa computacionalmente o que leva à opção de um algoritmo que opera iterativamente. Este modo de operar oferece duas vantagens que são exploradas pelo método proposto. A primeira é o tempo de operação, o resultado a cada iteração leva muito menos tempo para ser calculado, assim, o algoritmo se torna mais rápido. A segunda é a possibilidade de se encontrar uma solução aceitável antes do algoritmo finalizar todas as iterações, o que também acelera a resposta do algoritmo.

Outro fator relativo à velocidade na busca da solução é a inserção de um critério de parada do algoritmo iterativo. Para o algoritmo proposto, o critério empregado é a tolerância, a qual é considerada como a diferença entre duas iterações consecutivas. O objetivo dessa inserção é reduzir o custo computacional ao assumir que uma iteração cujas mudanças somadas não superem a tolerância não apresenta resultados muito melhores do que a solução atual, e assim, pode se dizer que a solução final foi atingida. No trabalho é empregado a tolerância de $10e^{-12}$. Juntamente com a tolerância também se estabelece outro critério que é número máximo de iterações, o qual foi configurado para que não se ultrapassem as 500 iterações. As iterações contadas como critério de parada são correspondentes a cada atualização da matriz de pesos \mathbf{W} da equação (9), que também apresenta um limite máximo de iterações do CG para ser atualizada. De fato, o número de iterações que o algoritmo leva para atingir a solução é tão aquém desse limiar que o mesmo é tratado como medida de segurança para testes de implementação.

Dessa maneira o funcionamento do algoritmo proposto se trata do seguinte conjunto de etapas:

- Configurar os parâmetros iniciais: $\hat{\mathbf{f}}_0$, \mathbf{W}_0 , além de ω , λ e ε .
- Repetir até atingir o critério de parada:
 - Calcula o mínimo da função custo com algumas iterações do Gradiente Conjugado: $\hat{\mathbf{f}}_{k+1} = \arg \min_{\mathbf{f}} \|\mathbf{g} - \mathbf{H}\mathbf{f}_k\|_2^2 + \lambda \Upsilon(f_k)$ (RAMANI; FESSLER, 2010) $\Upsilon(f_k) = \|\mathbf{P}_C \mathbf{f}_k\|_1 + \omega \|\mathbf{P}_E \mathbf{f}_k\|_1$
 - Atualiza as matrizes de pesos para o $\hat{\mathbf{f}}$ encontrado: $\mathbf{W}_{C_{R-G}}$, $\mathbf{W}_{C_{B-G}}$ e \mathbf{W}_E conforme Equação (10).

A implementação do algoritmo proposto foi realizada em MATLAB, versão do ano de 2013, que é um ambiente de programação de operações matriciais muito eficiente, em um computador com as seguintes características: Processador Intel (R) Core(TM) i5-2450M, CPU de 2,5 GHz com memória RAM de 4,0 GB.

[...] O ambiente do MATLAB é um ambiente excelente para adquirir experiência com os algoritmos, realizar exercícios, e para produção de trabalho em escala pequena à média. Códigos de MATLAB para muitos dos algoritmos estão disponíveis por Protocolos de Transferências de arquivos anônimos. (KELLEY, 1995)

Possivelmente um computador com melhores qualidade que as mencionadas apresentará resultados ainda melhores em questão de performance.

6 EXPERIMENTOS

O algoritmo de resolução do problema de *Demosaicing* proposto neste trabalho é comparado com outros algoritmos do estado da arte (PALIY et al., 2007) (ZHANG; WU, 2005) para o CFA Bayer, e também com outro algoritmo de características semelhantes (SAITO; KOMATSU, 2008), o qual também trabalha com o conceito de problemas inversos, para outros padrões de CFA como o padrão RGBW e o CYGM.

O experimento proposto consiste na formação de imagens coloridas em simulações de captura de imagens digitais. Assim, o resultado de cada algoritmo pode ser comparado com as imagens que originaram os dados, e é calculado o PSNR e SSIM, que são as métricas de qualidade empregadas no experimento, além do tempo de processamento. Além disso, o experimento contará com duas etapas, a primeira consiste em observar a performance do sistema em uma situação sem ruído, e na segunda há a inserção de ruído para simular uma captura mais próxima da realidade. O ruído do segundo experimento apresenta distribuição gaussiana, com 35 dB de intensidade.

Foi empregada uma seleção de porções das imagens originais, vide Figura 20 para atender às condições de dimensionalidade do problema, verificadas no ambiente de simulação. Assim, cada porção (*patch*) é uma imagem de 60x60 *pixels*, e foram empregados *patches* das 24 imagens que compõe o conjunto de dados da Kodak, conforme mostrado na Figura 20 (FRANZEN... , 1999). A dimensão arbitrária de 60x60 *pixels* tem fundamento em trabalhos similares de comparação onde se atenta a detalhes das imagens, perceptíveis e influente às métricas de qualidade, SSIM e PSNR, quando a dimensão da imagem é mais reduzida.

Na Figura 20 há todos os *patches* utilizados no experimento, a escolha de cada uma deles tem como base o conceito de que imagens naturais apresentam regiões de suavidade e bordas definidas e síncronas (ZHANG; WU, 2005).

Conforme já mencionado anteriormente, há dois parâmetros a serem definidos ao se utilizar o algoritmo proposto, um deles trata da proporção de regularização, que é o parâmetro λ da Equação (7). Neste trabalho propôs-se um λ igual a 10^{-9} , o qual representa a proporção entre



Figura 20: Compilação de todos os *patches* do conjunto de dados da Kodak utilizadas no experimento deste trabalho, na qual cada *patch* tem a configuração dimensiona de 60x60 pixels. No conjunto de dados selecionado, optou-se por um conjunto de características bem distintas, com regiões mais suaves, elementos de textura, e bordas bem definidas.

o elemento de fidelidade dos dados e o *Prior* utilizado, como o problema apresenta inúmeras soluções e o *Prior* tem a função de inserir uma tendência de na minimização, se supos que os dados são muito confiáveis, dado o processo de captura ser composto por uma amostragem direta. A confiança que se tem leva a reduzir a variável λ para que a tendência inserida não desvie tanto do valor idealizado, o que resulta em melhor qualidade visual (PSNR e SSIM), mas não pode também ser tão ínfima a ponto de tender a zero porque atrasa a convergência da minimização, resultando em tempo maior de processamento. Através de vários testes do algoritmo proposto, verificou-se o desempenho equilibrado entre velocidade e aspecto visual quando o parâmetro λ é configurado em 10^{-9} , de modo que há a possibilidade de otimização para cada conjunto de dados, apesar de não ser esse o objetivo desta pesquisa.

Já o outro parâmetro é o ε apresentado na Equação (10), que evita a divisão por zero na etapa de atualização da matriz de pesos do IRLS-CG, nos experimentos foi empregado o parâmetro ε equivalente a 2,5. Outra vez foram verificados através de testes de implementação os efeitos causados por atribuições de valores maiores e menores dessa variável no comportamento do algoritmo. Em regiões de suavidade, o produto vetorial $\mathbf{P}\mathbf{f}$ apresenta alguns valores próximos ou até iguais a zero, o que leva o cálculo do peso w_i na equação (10) a um valor muito elevado se não houver a compensação de ε para reduzir. De modo que os resultados dos testes com ε igual a 2,5 revelaram resultados muito bons sem distorções causadas por ponderações irregulares no IRLS.

O parâmetro ω , apresentado na Equação (17), foi verificado no experimento, pois se tem conhecimento que há um ω específico para cada imagem que fornece o melhor resultado para a o conjunto de dados em questão. Como o tema ainda requer estudos mais aprofundados para estimar um valor de ω mais apropriado para cada situação a partir dos dados, optou-se por um ω que não privilegie nem a sincronia de bordas de objetos nem a suavidade de regiões uniformes, ou seja, ω equivalente a 1.

6.1 RESULTADOS

Os resultados obtidos nos experimentos estão expressos na forma de tabelas descritas na sequência, há uma tabela para cada CFA, para situações sem ruído e com ruído de distribuição gaussiana equivalente a 35 dB.

É possível observar, nas Tab. 1 e ??, que o algoritmo proposto apresenta qualidade de reconstrução comparável a outras alternativas do estado da arte, na condição de captura com o uso de CFA Bayer. Apesar de não se sobressair tanto nessa captura, até mesmo pelo fato das

Tabela 1: Valores médios de tempo computacional (segundos), PSNR (dB) e SSIM, para todas as imagens do experimento com os CFAs Bayer, RGBW e CYGM sem inserção de ruído, com destaques para as melhores performances nas três métricas apresentadas de cada CFA, e os Priors numerados correspondem respectivamente às Equação (14), (15) e (16).

CFA	método	valor médio		
		Tempo	PSNR	SSIM
Bayer	Interpolação Dir. a Bordas	0.051	25.08	0.9193
	<i>Extended Total Variation</i>	0.567	28.17	0.8873
	DLMMSE	0.234	36.31	0.9818
	LPA-ICI	0.033	36.68	0.9821
	Algoritmo proposto (\mathbf{P}_{E1})	0.259	35.03	0.9765
	Algoritmo proposto (\mathbf{P}_{E2})	0.303	35.45	0.9785
	Algoritmo proposto (\mathbf{P}_{E3})	0.307	35.47	0.9786
RGBW	<i>Extended Total Variation</i>	0.513	29.27	0.9207
	Algoritmo proposto (\mathbf{P}_{E1})	0.253	34.28	0.9749
	Algoritmo proposto (\mathbf{P}_{E2})	0.253	34.78	0.9776
	Algoritmo proposto (\mathbf{P}_{E3})	0.258	34.86	0.9779
CYGM	<i>Extended Total Variation</i>	0.723	29.99	0.9413
	Algoritmo proposto (\mathbf{P}_{E1})	0.270	34.57	0.9759
	Algoritmo proposto (\mathbf{P}_{E2})	0.277	34.98	0.9775
	Algoritmo proposto (\mathbf{P}_{E3})	0.280	35.06	0.9777

propostas de (PALIY et al., 2007) e (ZHANG; WU, 2005) terem sido desenvolvidas com um foco maior neste CFA, os resultados obtidos são muito bons na situação sem inserção de ruído, como visto na Tab. 1.

É visível a capacidade do algoritmo proposto de manter o nível de qualidade para os outros CFAs utilizados. Já nos resultados do experimento com ruído, conforme disposto na Tabela 2, houve uma queda na qualidade das reconstruções de todas as soluções, mas os resultados dos algoritmos do estado da arte ficaram mais próximos do algoritmo proposto. Essa diminuição da qualidade (SSIM e PSNR) se dá pela própria inserção do ruído, considerando que a aquisição dos dados ignorando o ruído torna a solução naturalmente mais próxima da imagem original, do que dados distorcidos por ruído, ainda que o mesmo seja levemente perceptível. Uma das possíveis razões desse comportamento é o a funcionalidade do algoritmo ser semelhante à regularização, que é um método voltado a situações ruidosas.

Nas Figuras 21, 22 e 23 seguem alguns dos resultados obtidos nos experimentos descritos com o respectivo resultado de capturas sem ruído com CFA Bayer, RGBW e CYGM, para verificação do aspecto visual das reconstruções, enquanto que nas Figuras 24, 25 e 26, as reconstruções são de capturas com ruído.

Tabela 2: Valores médios de tempo computacional (segundos), PSNR (dB) e SSIM, para todas as imagens do experimento com os CFAs Bayer, RGBW e CYGM com inserção de ruído gaussiano equivalente a 35 dB, com destaques para as melhores performances nas três métricas apresentadas de cada CFA, e os Priors numerados correspondem respectivamente às Equação (14), (15) e (16).

CFA	método	valor médio		
		Tempo	PSNR	SSIM
Bayer	Interpolação Dir. a Bordas	0.051	24.93	0.9027
	<i>Extended Total Variation</i>	0.585	27.94	0.8778
	DLMMSE	0.229	34.73	0.9664
	LPA-ICI	0.033	34.87	0.9658
	Algoritmo proposto (\mathbf{P}_{E1})	0.263	33.84	0.9621
	Algoritmo proposto (\mathbf{P}_{E2})	0.307	34.24	0.9651
	Algoritmo proposto (\mathbf{P}_{E3})	0.310	34.26	0.9654
RGBW	<i>Extended Total Variation</i>	0.466	28.66	0.8999
	Algoritmo proposto (\mathbf{P}_{E1})	0.243	32.46	0.9466
	Algoritmo proposto (\mathbf{P}_{E2})	0.252	32.82	0.9498
	Algoritmo proposto (\mathbf{P}_{E3})	0.255	32.89	0.9503
CYGM	<i>Extended Total Variation</i>	0.491	29.425	0.9239
	Algoritmo proposto (\mathbf{P}_{E1})	0.260	32.96	0.9532
	Algoritmo proposto (\mathbf{P}_{E2})	0.278	33.26	0.9559
	Algoritmo proposto (\mathbf{P}_{E3})	0.288	33.31	0.9564

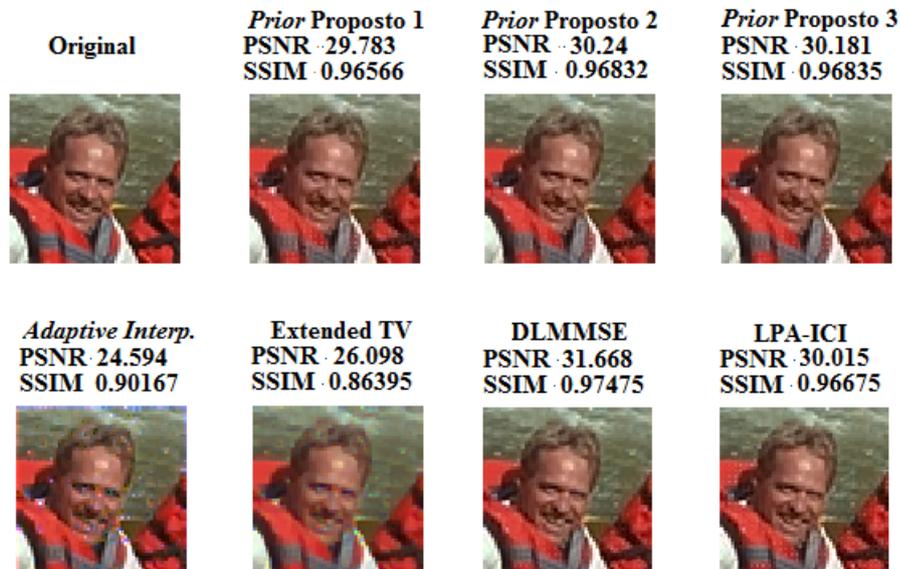


Figura 21: No canto superior esquerdo se encontra a imagem original que gerou os dados que foram utilizados para a reconstruções nas outras posições com captura por padrão Bayer, com os resultados dos *Priors* propostos, e os algoritmos propostos em (J.E. Adams Jr.; J. F. Hamilton Jr., 1997), (SAITO; KOMATSU, 2008), (ZHANG; WU, 2005) e (PALIY et al., 2007).



Figura 22: No canto superior esquerdo se encontra a imagem original que gerou os dados que foram utilizados para a reconstruções nas outras posições com captura por padrão RGBW, com os resultados dos *Priors* propostos, e os algoritmo proposto (SAITO; KOMATSU, 2008).



Figura 23: No canto superior esquerdo se encontra a imagem original que gerou os dados que foram utilizados para a reconstruções nas outras posições com captura por padrão CYGM, com os resultados dos *Priors* propostos, e os algoritmo proposto (SAITO; KOMATSU, 2008).



Figura 24: No canto superior esquerdo se encontra a imagem original que gerou os dados com ruído que foram utilizados para a reconstruções nas outras posições com captura por padrão Bayer, com os resultados dos *Priors* propostos, e os algoritmos propostos em (J.E. Adams Jr.; J. F. Hamilton Jr., 1997), (SAITO; KOMATSU, 2008), (ZHANG; WU, 2005) e (PALIY et al., 2007).



Figura 25: No canto superior esquerdo se encontra a imagem original que gerou os dados com ruído que foram utilizados para a reconstruções nas outras posições com captura por padrão RGBW, com os resultados dos *Priors* propostos, e os algoritmo proposto (SAITO; KOMATSU, 2008).



Figura 26: No canto superior esquerdo se encontra a imagem original que gerou os dados com ruído que foram utilizados para a reconstruções nas outras posições com captura por padrão CYGM, com os resultados dos *Priors* propostos, e o algoritmo proposto (SAITO; KOMATSU, 2008).

7 CONCLUSÃO

Há atualmente diversos métodos de *Demosaicing* com grande qualidade e desempenho, e a proposta desse trabalho é apresentar um algoritmo de *Demosaicing* com características comparáveis aos algoritmos do estado da arte e a versatilidade de operar com diversos CFAs. Os detalhes do algoritmo proposto foram descritos nos capítulos anteriores, e se estabeleceu uma maneira de verificar a performance da proposta perante outras soluções. A maneira estabelecida consiste em um experimento com a utilização de imagens que compõe o conjunto de dados da Kodak, e é analisada a performance do algoritmo proposto e de outras soluções da literatura quanto ao tempo computacional, PSNR e SSIM médios da solução.

No experimento, há duas situações que são verificadas: a situação de captura sem ruído, e a captura ruidosa em que o ruído foi estabelecido com valor nível de 35dB. Para cada uma dessas situações, foram testados os três CFAs, existentes comercialmente, descritos nesta dissertação: Bayer, RGBW e CYGM.

De acordo com os resultados obtidos se pode perceber a qualidade do algoritmo proposto, e a influência do prior na qualidade dos resultados. O *prior* 1 da Equação (14), apresenta resultados mais rápidos que os outros priors apresentados, uma das causas desse comportamento é a composição do primeiro prior, que anula tanto elementos vermelhos e azuis, o que agiliza as operações da minimização. Apesar de oferecer resultados mais rapidamente, a qualidade do primeiro prior foi inferior aos outros dois *Priors* apresentados, que consideravam os três canais. Esse aspecto pode ser explicado pelas operações do segundo e terceiro prior, respectivamente descritos pelas Equação (15) e (16) lidarem com todos os canais de cor da imagem, ou seja, ao manipular mais informações o algoritmo foi capaz de chegar a resultados melhores. A superioridade da qualidade verificada nos resultados do terceiro prior sugerem que considerar mais a informação contida no canal verde, que corresponde à faixa mais central do espectro luminoso visível, contribui para estimativas mais precisas do algoritmo proposto, no conjunto de dados estabelecidos no experimento.

Verificou-se a versatilidade do algoritmo proposto, sem, no entanto, reduzir a quali-

dade dos resultados. Mesmo sob o efeito do ruído, a proposta desenvolvida pôde lidar com o problema de *Demosaicing* com todos os CFAs, e mostrou-se de grande qualidade. Abaixo seguem os objetivos declarados na início desta dissertação que serviram como guias para o desenvolvimento da pesquisa:

- Estruturar um algoritmo de minimização utilizando o método IRLS-CG com bons resultados. O objetivo foi cumprido satisfatoriamente, uma vez que permitiu o procedimentos às etapas seguintes da pesquisa.
- Propor um termo de regularização capaz de proporcionar uma minimização rápida, coerente e estável. Outro objetivo cumprido pela utilização de um *Prior* que percebe as características mais importantes das imagens para o observador e as preserva para não perder qualidade visual nas reconstruções.
- Comparar resultados obtidos de PSNR e SSIM (WANG et al., 2004) entre algoritmos do estado da arte, com o algoritmo apresentado neste trabalho. Com os dois primeiros objetivos atingidos, este objetivo se torna simples, uma vez que o experimento tenha sido proposto.
- Verificar a tendência de qualidade dos resultados em função do padrão de CFA utilizado, e elaborar conclusões sobre o que foi observado. Através dos resultados médios, é possível atribuir ao padrão de CFA Bayer uma qualidade muito boa, não é por acaso que é amplamente utilizado nas câmeras digitais atualmente. Ainda assim, é possível que uma configuração de parâmetros mais voltada para algum padrão de CFA específico mude este quadro.

Assim, ao mesmo tempo que os objetivos estabelecidos no trabalho foram cumpridos, como visto acima, também surgem novas linhas de raciocínio para aprimorar ainda mais o desenvolvimento do método de *Demosaicing*.

7.1 TRABALHOS FUTUROS

Uma das vertentes para novas pesquisas que derivam do trabalho realizado nesta dissertação compreende a estimativa do parâmetro ω que permite uma otimização maior, mas varia com cada imagem trabalhada. Com a capacidade de se configurar o parâmetro ω para um valor mais próximo da situação ótima do que um ω genérico, há uma perspectiva de melhorar a eficiência do algoritmo pelo mesmo se adaptar ao conjunto de dados trabalhados. Além disso, uma vez que

a intensidade do ruído se torne mais acessível para o algoritmo, é possível otimizar a atribuição do valor de λ o que elevaria o desempenho da solução estimada. Outra possibilidade que precisa de estudos mais aprofundados é a otimização individual para cada CFA, isso foge do escopo desta pesquisa, uma vez que o objetivo era a configuração de um conjunto de parâmetros e alterar somente o padrão de CFA utilizado na captura dos dados. Entretanto, acredita-se que uma otimização nessa vertente é muito promissora, pois proporcionaria a padrões diferentes do Bayer uma performance excelente, assim como os mais avançados algoritmos do estado-da-arte apresentam com o CFA de Bayer.

REFERÊNCIAS

- BARRETT, H. H.; MYERS, K. J. **Foundations of image science**. [S.l.]: Wiley-interscience, 2004. (Wiley Series in Pure and Applied Optics). ISBN 0471153001.
- BOVIK, A. **Handbook of image and video processing**. 1. ed. [S.l.]: Academic Press, 2000. ISBN 0-12-119790-5.
- CAMBRIDGE in Colour - Ruídos em imagens de Câmeras digitais - parte 1. 2015. Disponível em: <<http://www.cambridgeincolour.com/pt-br/tutorials/image-noise.htm>>.
- FRANZEN, Rich - Kodak Lossless True Color Image Suite. 1999. Disponível em: <<http://r0k.us/graphics/kodak/>>.
- FUGITA, R.; ZIBETTI, M.; PIPA, D. A NEW PRIOR FOR INVERSE PROBLEMS BASED DEMOSAICKING. **IX Workshop de Visão Computacional**, 2015.
- GUNTURK, B. et al. Demosaicking: color filter array interpolation. v. 22, n. 1, p. 44–54, jan. 2005. ISSN 1053-5888.
- HADAMARD, J. **Lectures on Cauchy's problem in linear partial differential equations**. [S.l.]: New Haven Yale University Press, 1923.
- HAMILTON, J. F.; ADAMS, J. E. Design of practical color filter array interpolation algorithms for digital cameras. **Proc SPIE**, v. 3028, p. 117–125, 1997.
- HERMAN, G.; KUBA, a. Discrete tomography in medical imaging. **Proceedings of the IEEE**, v. 91, n. 10, p. 1612–1626, out. 2003. ISSN 0018-9219. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1232196>>.
- HIRAKAWA, K.; PARKS, T. Adaptive homogeneity-directed demosaicing algorithm. **IEEE Transactions on Image Processing**, v. 14, n. 3, p. 360–369, mar. 2005. ISSN 1057-7149. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1395991>>.
- J.E. Adams Jr.; J. F. Hamilton Jr. **Adaptive color plan interpolation in single sensor color electronic camera**. [S.l.]: Google Patents, 1997.
- KELLEY, C. T. **Iterative Methods for Linear and Nonlinear Equations**. [S.l.]: Society for Industrial and Applied Mathematics, 1995. ISBN 978-0-89871-352-7.
- LAROCHE, C.; PRESCOTT, M. **Apparatus and method for adaptively interpolating a full color image utilizing chrominance gradients**. [S.l.]: Google Patents, 1994.
- LATHI, B. **Sinais e Sistemas Lineares**. 2. ed. [S.l.]: Bookman, 2007.
- LI, X.; GUNTURK, B.; ZHANG, L. Image Demosaicing: a Systematic Survey. **Electronic Imaging 2008 - International Society for Optics and Photonics**, 2008.

- MENON, D.; CALVAGNO, G. Regularization approaches to demosaicking. **IEEE Transactions on Image Processing**, v. 18, n. 10, p. 2209–20, out. 2009. ISSN 1941-0042.
- OPPENHEIM, A.; WILLISKY, A.; NAWAB, S. **Sinais e Sistemas**. 2. ed. [S.l.]: PEARSON, 2010. ISBN 978-85-7605-504-4.
- PALIY, D. et al. Spatially adaptive color filter array interpolation for noiseless and noisy data. **International Journal of Imaging Systems and Technology**, v. 17, n. 3, p. 105–122, 2007. ISSN 08999457.
- PRATT, W. K. **Digital image processing**. 4th. ed. [S.l.]: Wiley-interscience, 2007. ISBN 9780471767770.
- RAMANATH, R. et al. Color image processing pipeline. **IEEE Signal Processing Magazine**, v. 22, n. 1, p. 34–43, jan. 2005. ISSN 1053-5888.
- RAMANI, S.; FESSLER, J. A. An accelerated iterative reweighted least squares algorithm for compressed sensing MRI. **IEEE International Symposium on Biomedical Imaging**, p. 257–260, 2010.
- SAITO, T.; KOMATSU, T. Demosaicing approach based on extended color total-variation regularization. In: **IEEE Int. Conf. on Image Processing**. [S.l.]: Ieee, 2008. p. 885–888. ISBN 978-1-4244-1765-0.
- WANG, Z. et al. Image quality assessment: from error visibility to structural similarity. v. 13, n. 4, p. 600–12, abr. 2004. ISSN 1057-7149.
- ZAMPOLO, R. d. F.; GOMES, D. d. A.; SEARA, R. Análise de Métricas de Qualidade Visual Aplicadas na Caracterização de Limiares Perceptuais com Variação da Imagem de Referência. **XXVII SIMPOSIO BRASILEIRO DE TELECOMUNICAÇÕES - SBRT09**, 2009.
- ZANIN, L. G. S.; SCHNEIDER, F. K.; ZIBETTI, M. V. W. Análise SVD de Sistemas de Imageamento de Ultrassom Baseado na Reconstrução Inversa. In: **V SIIM**. [S.l.: s.n.], 2011. p. 1–4.
- ZHANG, L.; WU, X. Color demosaicking via directional linear minimum mean square-error estimation. v. 14, n. 12, p. 2167–2178, dez. 2005. ISSN 1057-7149.
- ZHANG, Y. et al. Novel color demosaicking for noisy color filter array data. **Signal Processing**, Elsevier, v. 92, n. 2, p. 455–464, fev. 2012. ISSN 01651684.
- ZIBETTI, M. V. W. **Restauração da resolução de seqüência de imagens usando regularização adaptativa**. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2003.
- ZIBETTI, M. V. W.; De Pierro, A. R. Separate magnitude and phase regularization in MRI with incomplete data: Preliminary results. In: **IEEE International Symposium on Biomedical Imaging**. [S.l.]: IEEE, 2010. p. 736–739. ISBN 978-1-4244-4125-9. ISSN 1945-7928.