



Carlos Eduardo Rodrigues Correia

**Desenvolvimento de PIV Ultra Preciso para Baixos
Gradientes usando abordagem Híbrida de Correlação
Cruzada e Cascata de Rede Neurais Convolucionais**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Metrologia da PUC-Rio

Orientador: Prof. Carlos Roberto Hall Barbosa

Coorientador: Prof. Igor Braga de Paula

Coorientador: Prof. Helon Vicente Hultmann Ayala

Rio de Janeiro

maio de 2021



Carlos Eduardo Rodrigues Correia

**Desenvolvimento de PIV Ultra Preciso para Baixos
Gradientes usando abordagem Híbrida de Correlação
Cruzada e Cascata de Rede Neurais Convolucionais**

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Metrologia da PUC-Rio. Aprovada pela Comissão Examinadora abaixo:

Prof. Carlos Roberto Hall Barbosa

Orientador

Programa de Pós-graduação em Metrologia – PUC-Rio

Prof. Igor Braga de Paula

Coorientador

Departamento de Engenharia Mecânica – PUC-Rio

Prof. Helon Vicente Hultmann Ayala

Coorientador

Departamento de Engenharia Mecânica – PUC-Rio

Prof. Luís Fernando Alzuguir Azevedo

Departamento de Engenharia Mecânica – PUC-Rio

Dr. Fabio Jessen Werneck de Almeida Martins

University of Duisburg-Essen

Prof. Karla Tereza Figueiredo Leite

Instituto de Matemática e Estatística – UERJ

Rio de Janeiro, 7 de Maio de 2021

Todos os direitos reservados. É proibida a reprodução total ou parcial, do trabalho sem autorização da universidade, do autor e do orientador.

Carlos Eduardo Rodrigues Correia

Graduou-se em Engenharia Mecânica na Pontifícia Universidade Católica do Rio de Janeiro em 2016 e em Engenharia Elétrica em 2017.

Ficha Catalográfica

Correia, Carlos Eduardo Rodrigues

Desenvolvimento de PIV ultra preciso para baixos gradientes usando abordagem híbrida de correlação cruzada e cascata de rede neurais convolucionais / Carlos Eduardo Rodrigues Correia ; orientador: Carlos Roberto Hall Barbosa ; coorientador: Igor Braga de Paula, Helon Vicente Hultmann Ayala. – 2021.

98 f. : il. color. ; 30 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Centro Técnico Científico, Programa de Pós-Graduação em Metrologia, 2021.

Inclui bibliografia

1. Metrologia – Teses. 2. PIV. 3. Velocimetria por imagem de partículas. 4. CNN. 5. Rede neural convolucional. 6. Montagem de rede neurais. I. Barbosa, Carlos Roberto Hall. II. Paula, Igor Braga de. III. Ayala, Helon Vicente Hultmann. IV. Pontifícia Universidade Católica do Rio de Janeiro. Centro Técnico Científico. Programa de Pós-Graduação em Metrologia. V. Título.

CDD:381.1

Agradecimentos

Dedico este trabalho à memória de meu pai, morto em 2020. Que sempre me apoiou em tudo que eu decidisse fazer. Agradeço a minha mãe por terem me dado apoio mesmo quando não concordavam com as minhas escolhas.

Agradeço fortemente aos meus orientadores, Carlos Hall, Igor Braga e Helon, que me apoiaram em um momento extremamente difícil e que me incentivaram para que eu conseguir finalizar o trabalho.

Agradeço também às agências financiadoras, como a Capes e o Cnpq, que me apoiam desde a graduação. Aos funcionários do PósMQI e do departamento de engenharia mecânica, que sempre ajudaram os alunos quando podiam.

Muito obrigado a todos que me apoiaram, sem vocês eu não teria conseguido.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) - Código de Financiamento 001.

Resumo

Correia, Carlos Eduardo Rodrigues; Barbosa, Carlos Roberto Hall; de Paula, Igor Braga; Ayala, Helon Vicente Hultmann. **Desenvolvimento de PIV Ultra Preciso para Baixos Gradientes usando abordagem Híbrida de Correlação Cruzada e Cascata de Rede Neurais Convolucionais**. Rio de Janeiro, 2021. 98p. Dissertação de Mestrado - Programa de Pós-graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro.

Ao longo da história a engenharia de fluidos vem se mostrando como uma das áreas mais importantes da engenharia devido ao seu impacto nas áreas de transporte, energia e militar. A medição de campos de velocidade, por sua vez, é muito importante para estudos nas áreas de aerodinâmica e hidrodinâmica. As técnicas de medição de campo de velocidade em sua maioria são técnicas ópticas, se destacando a técnica de *Particle Image Velocimetry (PIV)*. Por outro lado, nos últimos anos importantes avanços na área de visão computacional, baseados em redes neurais convolucionais, se mostram promissores para a melhoria do processamento das técnicas ópticas. Nesta dissertação, foi utilizada uma abordagem híbrida entre correlação cruzada e cascata de redes neurais convolucionais, para desenvolver uma nova técnica de PIV. O projeto se baseou nos últimos trabalhos de PIV com redes neurais artificiais para desenvolver a arquitetura das redes e sua forma de treinamento. Diversos formatos de cascata de redes neurais foram testados até se chegar a um formato que permitiu reduzir o erro em uma ordem de grandeza para escoamento uniforme. Além do desenvolvimento da cascata para escoamento uniforme, gerou-se conhecimento para fazer cascatas para outros tipos de escoamentos.

Palavras-chave

PIV; Velocimetria por imagem de partículas; CNN; Rede neural convolucional; Montagem de redes neurais.

Abstract

Correia, Carlos Eduardo Rodrigues; Barbosa, Carlos Roberto Hall (Advisor); de Paula, Igor Braga (Co-Advisor); Ayala, Helon Vicente Hultmann (Co-Advisor). **Development of Ultra Precise PIV for Low Gradients Using Hybrid Cross-Correlation and Cascading Neural Network Convolutional Approach**. Rio de Janeiro, 2021. 98p. Dissertação de Mestrado - Programa de Pós-graduação em Metrologia, Pontifícia Universidade Católica do Rio de Janeiro.

Throughout history, fluid engineering is one of the most important areas of engineering due to its impact in the areas of transportation, energy and the military. The measurement of velocity fields is important for studies in aerodynamics and hydrodynamics. The techniques for measuring the velocity field are mostly optical techniques, with emphasis on the PIV technique. On the other hand, in recent years, important advances in computer vision, based on convolutional neural networks, have shown promise for improving the processing of optical techniques. In this work, a hybrid approach between cross-correlation and cascade of convolutional neural networks was used to develop a new PIV technique. The project was based on the latest work of PIV with an artificial neural network to develop the architecture of the networks and their form of training. Several cascade formats of neural networks were tested until they reached a format that allowed the error to be reduced by an order of magnitude for uniform flow. In addition to the development of the cascade for uniform flow, knowledge was generated to make cascades for other types of flows.

Keywords

PIV; Particle image velocimetry; CNN; Convolutional neural network; Assembly network

Sumário

1	Introdução	14
1.1	Objetivo	15
1.2	Estrutura da Dissertação	16
2	Revisão Bibliográfica	17
2.1	Particle Image Velocimetry	17
2.1.1	Sistema de iluminação	19
2.1.2	Partículas traçadoras	20
2.1.3	Sistema de aquisição de imagens	21
2.1.4	Sincronização	21
2.1.5	Processamento	22
2.2	Redes Neurais Artificiais	24
2.2.1	Neurônio	26
2.2.2	Funções de ativação	27
2.2.3	Conexões	31
2.2.4	Passo	31
2.2.5	<i>Padding</i>	32
2.3	Redes Neurais Convolucionais Profundas	32
2.3.1	Camada Convolucional	32
2.3.2	Camada de <i>downsampling</i>	33
2.3.3	Aprendizado	33
2.3.4	Backpropagation	34
2.3.5	Montagem de Rede Neurais	34
2.3.6	Cascata de Redes Neurais	35
2.4	Redes Neurais aplicadas a PIV	36

3 PIV com redes neurais – Implementação, validação e testes de modelo da literatura	39
3.1 Descrição da Rede Convolucional	39
3.2 Descrição da Cascata de Redes Convolucionais	40
3.3 Descrição do Dataset	40
3.4 Resultados	41
3.4.1 Validação do programa em Python	41
3.4.2 Análise de variação de diâmetro	44
3.4.3 Análise de variação de concentração	45
3.4.4 Análise em condições ideais	47
3.4.5 Análise de erro para imagem com gradientes	52
3.5 Considerações para o aprimoramento de modelos	56
4 Resultados	58
4.1 Modelo Híbrido Correlação Cruzada – Rede Convolucional (Rede64 Lee)	58
4.1.1 Arquitetura	58
4.1.2 Dataset	59
4.1.3 Resultados dos Testes de Validação	59
4.1.4 Teste de Robustez da Rede64 Lee	61
4.1.5 Considerações acerca da Rede64 Lee	64
4.2 Modelo híbrido com rede neural baseada no trabalho de Sun et al. (2013)	64
4.2.1 Arquitetura	64
4.2.2 Dataset	64
4.2.3 Resultados dos testes de validação	65
4.2.4 Considerações acerca da Rede64 Sun	69
4.3 Modelo com três redes em paralelo (Rede64M1 Sun)	70
4.3.1 Arquitetura	70
4.3.2 Dataset	71

4.3.3	Resultados dos testes de validação	71
4.3.4	Teste de Robustez	72
4.3.5	Considerações sobre a Rede64M1 Sun	74
4.4	Modelo de Cascata híbrida com especialização por diâmetro de partícula (RedeD64M1 64M2 Sun)	75
4.4.1	Arquitetura para a Rede de medição de diâmetro (Rede Diam)	76
4.4.2	Dataset para a medição de diâmetro e treinamento	76
4.4.3	Resultados da medição de diâmetro	76
4.4.4	Módulos Especializados	79
4.4.5	Teste dos módulos especializados	80
4.4.6	Teste de robustez	81
4.4.7	Considerações acerca da RedeD64M1 64M2 Sun.	84
4.5	Modelo de Cascata híbrida de 3 níveis (Rede64M1-32M2 Sun)	85
4.5.1	Arquitetura	85
4.5.2	Dataset	86
4.5.3	Resultados dos testes de validação	86
4.5.4	Resultados do Teste de Robustez	88
4.6	Resultado: Análise de um jato laminar	91
4.7	Considerações sobre a Rede64M1-32M2	92
5	Conclusões	93
5.1	Sugestões para trabalhos futuros	95
6	Referências Bibliográficas	96

Lista de Figuras

Figura 1 – Visão esquemática da técnica PIV – Adaptado de (RAFFEL, WILLERT e KOMPENHANS, 1998)	18
Figura 2 - Estruturas ópticas para criação de plano de iluminação	19
Figura 3 - Sincronização câmera laser	22
Figura 4 - Mapa de correlação cruzada	23
Figura 5 - Esquemático de um moderno neurônio de McCulloch e Pitts	27
Figura 6-Curva da função de ativação Linear	28
Figura 7-Curva da função de ativação Sigmoide	29
Figura 8-Curva da função de ativação ReLU	30
Figura 9-Curva da função de ativação Leaky ReLU	31
Figura 10- Processo de convolução	32
Figura 11 -Camada de downsampling usando a função de max pool	33
Figura 12-Rede Convolucional.	39
Figura 13 - Diagrama da cascata de redes convolucionais	40
Figura 14 - Valor medido versus valor real em cada estágio da rede implementada em Python, com base no método proposto no trabalho de (LEE, YANG e YIN, 2017).	42
Figura 15 - Comparação entre os valores medido e reais dos três modelos	43
Figura 16- Histograma dos três modelos para um teste de validação	43
Figura 17 - RMSE e Erro Médio da análise da variação do diâmetro	44
Figura 18 - Probabilidade de Sucesso de acordo com o diâmetro das partículas	45
Figura 19 - RMSE e Erro Médio para análise de variação de concentração	46
Figura 20 - Probabilidade de Sucesso de acordo com a concentração	47
Figura 21 - Valor medido versus valor real para concentração de 0,05 ppp e diâmetros de 2,5 pixels (primeira figura) e 4,0 pixels (segunda figura)	48
Figura 22 - Histogramas do erro para concentração de 0,05ppp e diâmetros de 2.5 (figura superior) e 4.0 (figura inferior) pixels	49
Figura 23 - Análise RMSE e Erro Médio para concentração de 0,05ppp e diâmetros de 2.5 e 4.0 pixels respectivamente	50
Figura 24 - Jato Turbulento PIV challenge	51

Figura 25 - Erro médio e RMSE para variação de deslocamento no jato turbulento	52
Figura 26 - RMSE e erro médio para variação de gradiente	53
Figura 27 - RMSE e erro médio para diferentes gradientes e deslocamentos	54
Figura 28 - Teste do seno	55
Figura 29 – Campo de deslocamento de Jato Laminar	56
Figura 30 – Deslocamento mensurado x Deslocamento real das partículas	60
Figura 31 – RMSE e Erro Médio (Rede64 Lee)	60
Figura 32 – Histograma do Erro. Gráfico da esquerda - Rede64 Lee; gráfico da direita (WIDIM)	61
Figura 33 – Probabilidade de sucesso de medição por diâmetro de partícula (Rede64 Lee).	62
Figura 34 - RMSE e Erro Médio por diâmetro de partícula(Rede64 Lee)	62
Figura 35 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64 Lee)	63
Figura 36- RMSE e Erro Médio para diferentes concentrações de partículas (Rede64 Lee)	63
Figura 37-Deslocamento estimado x deslocamento real (Rede64 Sun)	65
Figura 38 - RMSE e Erro Médio (Rede64 Sun)	66
Figura 39- Histograma do Erro (Rede64 Sun)	66
Figura 40 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64 Sun)	67
Figura 41 - RMSE e Erro Médio por diâmetro de partícula (Rede64 Sun)	68
Figura 42 – Probabilidade de sucesso de medição para diferentes de concentração de partículas (Rede64 Sun).	69
Figura 43 - RMSE e Erro Médio para diferentes concentrações de partículas (Rede64 Sun).	69
Figura 44 - Esquemático Rede64M1 Sun.	70
Figura 45 - RMSE e Erro Médio (Rede64M1 Sun)	71
Figura 46 - Histograma do Erro (Rede64M1 Sun)	72
Figura 47 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64M1 Sun)	72
Figura 48 - RMSE e Erro Médio por diâmetro de partícula(Rede64M1 Lee)	73
Figura 49 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64M1 Sun)	73

Figura 50 - RMSE e Erro Médio para diferentes concentrações de partículas (Rede64M1 Sun)	74
Figura 51 – Esquema RedeD64M1 – 64M2 Sun	75
Figura 52 – Arquitetura Rede Diam.	76
Figura 53 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede Diam).	77
Figura 54 – RMSE e Erro Médio para diferentes concentrações de partículas (Rede Diam).	78
Figura 55 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede Diam).	79
Figura 56 - RMSE e Erro Médio por diâmetro de partícula(Rede Diam)	79
Figura 57 – RMSE dos módulos especializados de acordo com o diâmetro da partícula (Módulos especializados).	81
Figura 58 – Probabilidade de sucesso de medição para variação de concentração de partículas (RedeD64M1-64M2 Sun)	82
Figura 59 - RMSE e Erro Médio para diferentes concentrações de partículas (RedeD64M1-64M2 Sun)	83
Figura 60 - Probabilidade de sucesso de medição por diâmetro de partícula (RedeD64M1-64M2 Sun)	83
Figura 61 - RMSE e Erro Médio por diâmetro de partícula (RedeD64M1-64M2 Sun)	84
Figura 62 - Esquemático Rede64M1 Rede32M2 Sun.	86
Figura 63 - Deslocamento mensurado x deslocamento real (Rede64M1-32M2 Sun)	87
Figura 64 - RMSE e Erro Médio (Rede64M1-32M2 Sun).	88
Figura 65 - Histograma do Erro (Rede64M1-32M2 Sun)	88
Figura 66 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64M1-32M2 Sun)	89
Figura 67 - RMSE e Erro Médio por diâmetro de partícula (Rede64M1-32M2 Sun)	89
Figura 68 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64M1-32M2 Sun)	90
Figura 69 - RMSE e Erro Médio para diferente concentrações de partículas (Rede64M1-32M2 Sun)	90

Figura 70 – (a) Jato Laminar (Rede 64 Lee) ,(b) Jato Laminar (Rede64M1-32M2 Sun).

92

1

Introdução

Dos tempos remotos até os dias de hoje o estudo de escoamentos evoluiu bastante e, atualmente, permite que sejam previstos com alguma antecedência a hora que ocorrerão chuvas, o tamanho de furacões e o caminho que irão percorrer, o índice pluviométrico de um mês ou possíveis cenários de aquecimento global (NEVES, GALLARDO e VECCHIA, 2017). Do ponto de vista de engenharia, observou-se um enorme avanço da engenharia de transporte de fluidos por tubulações. No cenário atual, extrai-se petróleo de rochas porosas bem abaixo do leito marinho e bombeia-se esse óleo através de dutos por quilômetros de distância, com confiabilidade e alguma previsibilidade. O transporte de materiais e pessoas também exibiu uma grande evolução no último século, devido ao desenvolvimento da mecânica dos fluidos.

A compreensão dos diversos fenômenos associados a escoamentos foi auxiliada ao longo da história por experimentação e visualização desses escoamentos. Atualmente, as técnicas de visualização foram combinadas com técnicas de processamento digital de imagens, de modo a fornecer informações quantitativas acerca dos escoamentos. Essa metodologia de medição de escoamentos é conhecida como velocimetria por imagem de partícula (PIV- *Particle Image Velocimetry*). A técnica de PIV se baseia na aquisição de imagens do escoamento com partículas traçadoras. A captura das imagens deve ser feita de forma que o deslocamento dessas partículas traçadoras de uma imagem para outra seja reconhecível. Na metodologia padrão, a estimação do deslocamento das partículas nas imagens é feita com o uso de correlação cruzada (RAFFEL, WILLERT e KOMPENHANS, 1998). A partir da estimação do deslocamento das partículas extrai-se um campo de velocidades do escoamento (RAFFEL, WILLERT e KOMPENHANS, 1998).

A técnica de PIV já é bem estabelecida e, atualmente, uma parte considerável dos laboratórios de mecânica dos fluidos ao redor do mundo dispõe de sistemas de medição PIV. Recentemente, o desenvolvimento dos algoritmos de Inteligência Artificial (IA) e redes neurais convolucionais (Convolutional Neural Networks – CNN) tem se mostrado como alternativa interessante para o processamento das imagens de PIV. O trabalho (GRANT, PAN, *et al.*, 1998) é um dos pioneiros no uso de redes neurais para PIV. Os trabalhos da literatura, dedicados ao tema, demonstraram que, de fato, as redes neurais podem ser utilizadas para a

estimação do deslocamento de partículas em imagens. Entretanto, a metodologia ainda não é amplamente adotada na comunidade. Isso se deve ao fato de que as ferramentas baseadas em redes neurais para realização de PIV ainda carecem de robustez e flexibilidade para aplicações práticas. Na prática, existem inúmeras situações onde as imagens apresentam nuances que são difíceis de serem totalmente previstas e cobertas no treinamento das redes.

Nesta dissertação de mestrado em Metrologia, buscou-se combinar técnicas tradicionais de PIV com as redes neurais, de modo a reduzir a faixa de parâmetros de treinamento das redes. A ideia é utilizar estratégias já estabelecidas na literatura como (SCARANO, 2002), por exemplo, o processamento de múltiplos passes e deformação de janelas, ambas baseadas em correlação cruzada para estimação grosseira dos deslocamentos, com resolução da ordem de pixels. Já a rede neural é utilizada somente para estimações refinadas com resolução sub-pixel. Sabe-se que os algoritmos padrões de estimação dos deslocamentos das partículas com resolução sub-pixel têm contribuição relevante para o custo computacional da técnica de PIV tradicional (RAFFEL, WILLERT e KOMPENHANS, 1998). Assim, procurou-se associar a flexibilidade e robustez dos métodos tradicionais de PIV com a capacidade de processamento das redes neurais, de modo a obter estimações mais exatas do deslocamento das partículas a partir de imagens. Do ponto de vista metrológico, isso reduz a incerteza de medição da técnica e pode contribuir para que o método se torne uma referência para a calibração de medidores de velocidade ou vazão.

1.1

Objetivo

Esta dissertação de mestrado em Metrologia tem como objetivo geral desenvolver um método visual, não intrusivo, de extração precisa de campos de velocidade de escoamentos a partir de imagens de partículas. O método desenvolvido se baseia na técnica de PIV (*Particle Image Velocimetry*), no entanto nesse trabalho a parte numérica de interpolação subpixel será substituída pelo uso de rede neurais. Este trabalho é inspirado na grande expansão da área de processamento de imagens devido ao uso de rede profundas convolucionais (LEE, YANG e YIN, 2017) (RABAULT, KOLAAS e JENSEN, 2017).

1.2

Estrutura da Dissertação

No Capítulo 2 é realizada uma análise bibliográfica sobre as técnicas de PIV e de rede neurais. Faz-se uma revisão sobre os fundamentos de cada técnica. No final do capítulo é feita uma contextualização dos trabalhos de PIV envolvendo redes neurais,

No capítulo 3 analisa-se uma Rede Neural proposta no trabalho (LEE, YANG e YIN, 2017). O objetivo foi avaliar o desempenho da rede e identificar limitações para que propostas de melhoria pudessem ser avaliadas no capítulo seguinte.

Testes com diferentes arquiteturas de redes neurais combinadas com o método de PIV convencional são apresentados no capítulo 4 e no capítulo 5 faz-se um resumo dos resultados obtidos e apresenta-se sugestões para trabalhos futuros.

2

Revisão Bibliográfica

O presente capítulo é dedicado à revisão da literatura nos temas pertinentes à dissertação e é dividido em quatro partes. Na primeira, são tratadas as referências do modelo padrão de PIV e a introdução de novos modelos de PIV. Em seguida, o histórico de redes neurais é descrito, e na terceira parte o foco é dado às redes neurais convolucionais. A última parte trata da descrição dos trabalhos de rede neurais em PIV. O leitor familiarizado com os conceitos básicos de PIV e de redes neurais pode iniciar a leitura deste capítulo pela última seção.

2.1

Particle Image Velocimetry

No início da década de 80 os primeiros trabalhos envolvendo *particle image velocimetry* (PIV) foram feitos nos laboratórios da DLR (*Deutsches Zentrum für Luft- und Raumfahrt e.V.*). No primórdio a técnica utilizava filmes químicos para o registro das imagens e métodos ópticos para o processamento, obtendo assim o campo de deslocamento das partículas no escoamento. Tal processo demandava um tempo de dois a três dias para o registro e processamento de um único par de imagens (RAFFEL, WILLERT e KOMPENHANS, 1998).

Na década de 90, a evolução das câmeras digitais, primeiro com sensores CCD (*Charge Coupled Device*) e depois com sensores CMOS (*Complementary Metal Oxide Semiconductor*), aumentaram significativamente a capacidade da técnica. Assim, imagens que demoravam várias horas para serem registradas e reveladas passaram a ser obtidas em frações de segundos. Outra consequência do uso de câmeras digitais foi a troca dos meios ópticos pelo uso do computador. A utilização de software para processar as imagens reduziu o tempo de processamento para alguns segundos em grandes laboratórios. Além disso, permitiu o uso de etapas de pré e pós-processamento das imagens, além de melhorias no processamento em si, o que provocou uma melhoria significativa dos dados obtidos (PAULA, ABRANTES e AZEVEDO, 2012).

Diversas variantes da técnica de PIV foram desenvolvidas nas últimas décadas, dentre as quais destacam-se o micro-PIV para medição de escoamentos em escala microscópica e as técnicas para medição das 3 componentes de velocidade em um plano (PIV

estereoscópico) e em um volume (PIV tomográfico e holográfico). Além disso, a evolução das câmeras com alta taxa de amostragem permitiu que sejam realizadas medições com alta resolução temporal (RAFFEL, WILLERT e KOMPENHANS, 1998).

A técnica de PIV (Particle Image Velocimetry) convencional consiste na estimativa do deslocamento de partículas traçadoras imersas em um escoamento. Uma visão esquemática da técnica pode ser observada na Figura 1. De acordo com o desenho, as partículas traçadoras são iluminadas por um feixe de luz. Essa iluminação é tipicamente pulsada, para que a posição instantânea das partículas seja capturada nas imagens. Aplicando-se um outro pulso de luz após um pequeno intervalo de tempo e registrando-se a imagem do escoamento pode ser possível identificar o deslocamento das partículas de uma captura para a outra. Utiliza-se o processo de correlação cruzada para estimativa do deslocamento de um conjunto de partículas da primeira imagem para a segunda imagem (RAFFEL, WILLERT e KOMPENHANS, 1998).




Figura 1 – Visão esquemática da técnica PIV – Adaptado de (RAFFEL, WILLERT e KOMPENHANS, 1998)

Nas subseções a seguir são descritos em mais detalhes alguns dos elementos da técnica de PIV, a saber: i) sistema de iluminação; ii) partículas traçadoras; iii) sistemas de aquisição de imagens; iv) sincronização e v) processamento.

2.1.1

Sistema de iluminação

Para fazer com que as partículas traçadoras sejam capturadas nas imagens do escoamento são usadas fontes de iluminação pulsadas de alta potência. Uma fonte que satisfaz esse requerimento são os lasers (RAFFEL, WILLERT e KOMPENHANS, 1998). Recentemente, os LEDs de alta potência têm se mostrado como uma alternativa interessante aos lasers, pelo custo ser muito mais baixo. Entretanto, a potência por área e pulso dos LEDs ainda é inferior aos lasers e, portanto, eles têm aplicação mais restrita a medições em líquidos, onde a demanda de energia é tipicamente menor do que em gases.

O feixe de luz da fonte de iluminação deve ser condicionado para iluminar somente a região do escoamento onde se deseja medir. No caso de medições em um plano (PIV planar), deve-se criar um plano de iluminação e para isso utilizam-se conjuntos de lentes esféricas e cilíndricas para o condicionamento do feixe de luz, conforme ilustrado na Figura 2. Para posicionar o plano de luz sobre a região de visualização são empregados espelhos para lasers de alta potência e com alta taxa de refletância (PAULA, ABRANTES e AZEVEDO, 2012).




Figura 2 - Estruturas ópticas para criação de plano de iluminação

2.1.2

Partículas traçadoras

As partículas traçadoras devem ser capazes de seguir fielmente o escoamento e refletir luz suficiente para que sejam observáveis pelo sistema de captura de imagens. Logo, pode-se inferir que densidade e tamanho são parâmetros importantes na escolha de partículas traçadoras.

O tempo de resposta de partículas muito pequenas (da ordem de alguns micrometros) pode ser estimado utilizando a Lei de Stokes e a diferença entre a densidade da partícula ρ_p e a densidade do fluido ρ_f . Lembrando que a lei de Stokes é válida para números de Reynolds (Re) baseados no diâmetro da partícula da ordem de 1, onde o Re é dado por

$$Re = \frac{\rho_f |U_p - U| d_p}{\mu_f}, \quad (1)$$

onde d_p é o diâmetro da partícula, μ_f a viscosidade dinâmica do fluido, U_p é a velocidade da partícula e U é a velocidade do escoamento. De acordo com a lei de Stokes, o retardo da partícula em relação ao fluido de aceleração $\vec{a} = dU/dt$ é dado por

$$U_p - U = \frac{d_p^2 (\rho_p - \rho_f)}{18\mu_f} \vec{a}, \quad (2)$$

Essa equação é de um sistema de 1ª ordem, cuja solução permite estimar a velocidade da partícula ao longo do tempo, conforme

$$U_p(t) = U \left[1 - \exp\left(-\frac{t}{\tau_p}\right) \right], \quad (3)$$

sendo τ_p o tempo característico de resposta da partícula, calculado por:

$$\tau_p = d_p^2 \frac{\rho_p}{18\mu_f}. \quad (4)$$

Um parâmetro adimensional interessante para esse problema é o número de Stokes, que relaciona o tempo de resposta da partícula em relação ao tempo de resposta do escoamento, na forma:

$$St_p = \frac{\tau_p}{\tau_f}, \quad (5)$$

De acordo com esta grandeza adimensional, quanto menor for o número de Stokes, mais fielmente a partícula acompanhará o escoamento. A partir da análise de Stokes, nota-se

que partículas pequenas tendem a seguir melhor o escoamento (tempo de resposta é proporcional ao quadrado do diâmetro).

A intensidade das partículas traçadoras nas imagens é proporcional à luz espalhada por essas partículas. Sabe-se que partículas pequenas espalham pouca luz. Logo, deve-se buscar partículas que possuam grande diferença de índice de refração em relação ao fluido de trabalho, para que possam ter alta capacidade de refletir a luz incidente pois, de acordo com a análise feita com a Lei de Stokes, é necessário que as partículas sejam suficientemente pequenas para que possam acompanhar o escoamento. Logo, observa-se que a escolha dessas partículas deve buscar um bom compromisso entre fidelidade de acompanhamento do escoamento e intensidade da reflexão de luz (PAULA, ABRANTES e AZEVEDO, 2012).

2.1.3

Sistema de aquisição de imagens

As câmeras utilizadas para PIV precisam ter alta eficiência na captura de fótons e serem capazes de capturar pelo menos duas fotos com intervalo de tempo pequeno entre as capturas. Além disso, todos os pixels da câmera têm que ser excitados e amostrados simultaneamente. As câmeras convencionais não satisfazem todos esses requisitos. Por isso, os equipamentos empregados na técnica de PIV são projetadas especialmente para esta aplicação.

2.1.4

Sincronização

Para fazer o registro das imagens das partículas em instantes de tempo bem definidos, é necessário que os pulsos de luz e as câmeras estejam bem sincronizados. No gráfico da Figura 3 pode ser visto o processo de sincronização entre as câmeras e a fonte luminosa. Para a sincronização dos dispositivos são utilizados geradores de pulsos (0 – 5 V) de alta precisão e com baixo *jitter*, pois a incerteza das medições depende fortemente da precisão no ajuste do tempo de disparo da fonte de iluminação e das câmeras.

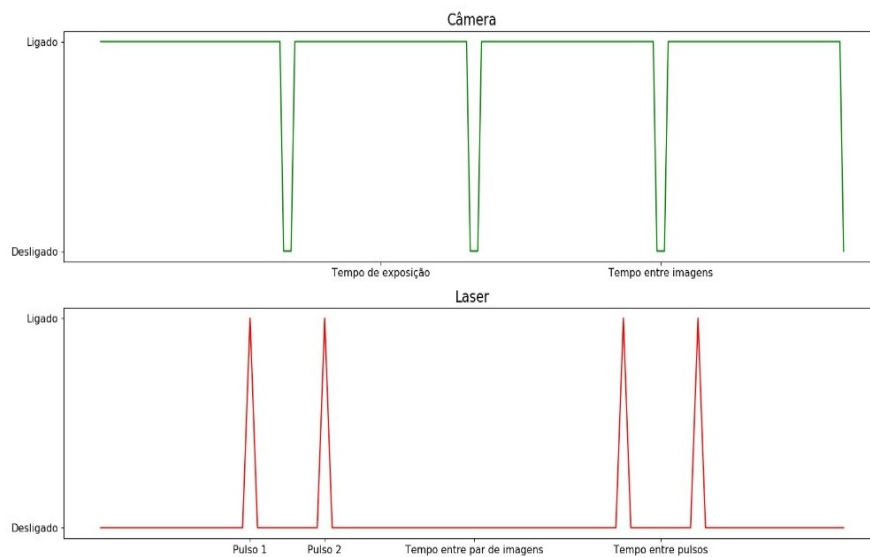


Figura 3 - Sincronização câmera laser

2.1.5

Processamento

Conforme já mencionado no texto, o deslocamento das partículas é estimado através da análise de um par de imagens, que serão chamadas nesta seção de imagens A e B. Para a detecção do movimento de um pequeno conjunto de partículas dentro da imagem, subdivide-se a imagem em pequenos pedaços, conhecidos como janelas de interrogação. Cada uma dessas janelas contém uma distribuição de partículas. O deslocamento do escoamento corresponde ao deslocamento médio das partículas dentro de cada janela de interrogação. O deslocamento das partículas é relativo entre as duas imagens. Toma-se a primeira captura como referência (imagem A) e busca-se encontrar o mesmo conjunto de partículas na segunda captura (imagem B). Sabendo-se o tempo entre a captura das duas imagens, pode-se inferir qual a velocidade do escoamento naquele local. O deslocamento das partículas é estimado por meio da correlação cruzada entre uma janela da imagem A e uma janela correspondente na imagem B. As janelas da imagem B são maiores que as janelas da imagem A, permitindo assim a formação do mapa de correlação, que é ilustrado na figura 4. O ponto de maior intensidade na figura corresponde ao ponto de maior correlação entre as figuras. Logo, a distância deste ponto até centro do mapa de correlação corresponde ao deslocamento do conjunto de partículas.




Figura 4 - Mapa de correlação cruzada

Para reduzir o custo computacional do método, a correlação cruzada é feita normalmente no domínio da frequência, através da aplicação da Transformada Rápida de Fourier (*Fast Fourier Transform* – FFT). Caso se esteja utilizando GPU, o uso da FFT pode ser desnecessária pois a correlação cruzada é paralelizável (TARASHIMA, 2010).

A resolução da matriz de correlação cruzada é a mesma das imagens, portanto, o local de máxima correlação é resolvido com resolução de pixel (posição do máximo na matriz de correlações). Essa resolução é muito grosseira e gera incertezas de medição da velocidade da ordem de 10 % (RAFFEL, WILLERT e KOMPENHANS, 1998). Para melhorar a resolução do método, faz-se necessária uma interpolação dos valores próximos ao pico de correlação. Na literatura, existem diversas funções de interpolação, sendo que as mais comuns são baseadas em funções gaussianas, devido ao fato da intensidade de luz refletida por partículas seguir, tipicamente, uma distribuição deste tipo. Com esses métodos de interpolação é possível estimar o deslocamento das partículas com resolução de sub-pixel. Em condições ideais de medição consegue-se resoluções de até 1/20 pixel (RAFFEL, WILLERT e KOMPENHANS, 1998). O esquema de interpolação gaussiana usando três pontos (RAFFEL, WILLERT e KOMPENHANS, 1998) pode ser adotado como

$$X_0 = \frac{\ln R_{(i-1,j)} - \ln R_{(i+1,j)}}{2\ln R_{(i-1,j)} - 4\ln R_{(i,j)} + 2\ln R_{(i+1,j)}} \quad (6)$$

$$Y_0 = \frac{\ln R_{(i,j-1)} - \ln R_{(i,j+1)}}{2\ln R_{(i,j-1)} - 4\ln R_{(i,j)} + 2\ln R_{(i,j+1)}}$$

onde i e j são a posição do pico da correlação e R o valor da correlação na posição.

O processamento das imagens pode dar origem a vetores espúrios. Normalmente, obtém-se em torno de 95 % de vetores válidos nas medições com a técnica de PIV. Em condições muito desafiadoras, pode-se chegar até 90 % de vetores válidos. Nessas condições é comum utilizar interpolações dos campos de velocidade para preencher os campos de velocidade nos locais onde foram detectados vetores espúrios. Abaixo deste limiar há erros excessivos nos campos de velocidade e as interpolações feitas sobre os campos de velocidade podem gerar campos artificiais.

Em um processamento PIV, a incerteza das medições é fortemente dependente dos métodos de interpolação sub-pixel e da quantidade de vetores espúrios. Métodos mais sofisticados de interpolação sub-pixel do que aquele apresentado na equação acima têm custo computacional mais elevado. Portanto, a escolha de um método de interpolação sub-pixel é normalmente feita com base em um compromisso entre exatidão e custo computacional. Apesar da técnica ser bem consolidada, acredita-se que ainda existe espaço para melhoria dessa etapa do processamento. Nesse contexto, as redes neurais se tornam interessantes, pois elas são ferramentas poderosas de interpolação e regressão de dados.

2.2

Redes Neurais Artificiais

Em 1943 o neurofisiologista Warren McCulloch e o matemático Water Pitts propuseram o primeiro modelo matemático para um neurônio, conhecido como MCP (MCCULLOCH e PITTS, 1943). O neurônio proposto possuía os cinco pressupostos listados a seguir:

1. O neurônio é binário (dispara ou não);
2. Cada neurônio possui função de ativação em degrau com um determinado limiar de disparo;
3. Todos os pesos de um neurônio possuem o mesmo valor;
4. Os neurônios possuem entradas inibidoras, que caso estejam ativas farão com que o neurônio não dispare, não importando o valor das outras entradas; e
5. O neurônio possui um tempo de processamento que causa um delay.

Em 1949, Donald O. Hebb publicou a monografia *the Organization of Behavior* (HEBB, 1949), que foi responsável pela criação da teoria neuropsicológica. No livro, Hebb comprova que o aprendizado e a memória do cérebro humano e dos animais estão relacionados à criação e modificação das ligações entre neurônios (teoria da plasticidade sináptica) e não ao desenvolvimento de novos neurônios (teoria da neurogênese), que ocorre em menor escala. Esta comprovação leva à alteração do terceiro pressuposto do neurônio de MCP, que passa a ser:

3. Os neurônios possuem um peso para cada entrada.

Além disso, Hebb também desenvolveu a regra Hebbiana para o aprendizado da rede. Essa regra estabelece que as conexões vão se apagando com o tempo, mas que quando os neurônios disparam juntos suas conexões se fortalecem. É dito que modelos de rede que seguem essa regra possuem aprendizado hebbiano.

Em 1958, Frank Rosenblatt apresentou o modelo de rede neural Perceptron (ROSENBLATT, 1958). O neurônio dessa rede segue o modelo MCP e a regra de aprendizado Hebbiana. A rede de um único neurônio de Rosenblatt só era capaz de resolver problemas lineares.

Em 1959, um grupo de Stanford desenvolveu a primeira rede neural com uso prático, as redes eram a ADALINE (ADaptative LINear Elements) e MADALINE (Multiple ADaptative LINear Elements) (WIDROW, 1960). A rede ADALINE utilizou a função de ativação de um degrau e como treinamento usou o *delta rule*. A rede foi utilizada para a realização binária. A rede MADALINE, por outro lado, foi uma rede contínua com função de ativação *sign*. A rede foi utilizada para filtrar chamadas telefônicas e continua em operação até hoje.

Marvin Minsky e Seymour Papert publicaram em 1969 um livro em que mostravam o principal problema que o modelo perceptron apresentava (MINSKY e PAPERT, 1969). Uma rede perceptron de duas camadas (entrada e saída) é incapaz de realizar tarefas não lineares, como obter o resultado da porta lógica do ou exclusivo. Caso se montasse uma rede neural com mais camadas, ou seja, uma rede MLP (*Multi Layer Perceptron*), a rede possuiria um número de interações grande de acordo com modelo de aprendizado utilizado até então. Essa comprovação reduziu o entusiasmo da academia sobre rede neurais e fez com a atenção se voltasse para outros modelos de *machine learning*.

Paralelamente, no trabalho (BRYSON, 1961) foi desenvolvido o método de otimização *backpropagation of error* ou *generalized delta rule* (método geral da regra adotada no ADALINE) para redes em geral. No entanto a regra só foi adotada pela primeira vez em redes neurais em 1974 no trabalho de Paul Werbos (WERBOS, 1974). Esse método resolve parcialmente o problema da rede neural analisado por Minsky e Papert (MINSKY e PAPERT, 1969) já que ele permite o aprendizado supervisionado de redes MLP com certa facilidade. No entanto este trabalho recebeu pouca atenção na época.

A pesquisa em rede neurais só voltou a receber mais atenção da área científica com o trabalho (HOPFIELD, 1982). A rede desenvolvida utilizava um novo tipo de rede recorrente mudando definitivamente o 5º pressuposto do neurônio MCP.

Em 1986, com o livro *Parallel Distributed Processing* (MCCLELLAND e RUMELHART, 1987), o sistema de backpropagation passou a ser amplamente conhecido pela comunidade como solução para o problema da linearidade da rede. Além disso, o uso da computação paralela, em especial de GPU (*Graphic Process Units*), vem facilitando o aumento do número de neurônios e o desenvolvimento de DNN (Deep Neural Networks).

A partir da década de 90, diversas formas de ANN (Artificial Neural Networks) foram desenvolvidas para resolver os mais diversos tipos de problemas, como por exemplo o uso de redes recorrentes para fazer previsões de séries temporais ou uso de rede convolucionais para reconhecer padrões.

Redes neurais são sistemas de nós interconectados que buscam imitar o processo de funcionamento do cérebro e assim obter a capacidade reconhecer padrões e agrupá-los, além de ser capaz de correlacionar e interpolar os dados. Nas seções a seguir será explicado o funcionamento de redes neurais e mais especificamente as redes neurais convolucionais.

2.2.1

Neurônio

O neurônio é o elemento mais básico de uma rede neural, sendo ele um único nó interconectado. Sua forma mais básica utilizada em redes MLP consiste na versão atualizada do neurônio de McCulloch e Pitts (BISHOP, 2015). A descrição básico do neurônio é:

- As ligações entre os neurônios ocorrem por meio de pesos adaptativos, que representam o processo de sinapse entre os neurônios;
- Uma entrada de bias também é aplicada a cada neurônio;
- Ocorre o processo de somatório ponderado dos valores de entradas pelos pesos sinápticos e com a entrada de bias; e
- Uma função de ativação não binária é aplicada ao valor obtido do somatório, fornecendo então o valor de resposta do neurônio

O processo do neurônio é apresentado na Figura 5.




Figura 5 - Esquemático de um moderno neurônio de McCulloch e Pitts

O processo é então matematicamente formulado através da equação (FABRO, 2001)

$$Output = f \left(bias + \sum_{i=1}^n W_i Input_i \right), \quad (7)$$

onde *Output* é a saída do neurônio, *f* é a função de ativação genérica, W_i é o peso sináptico da entrada *i*, $Input_i$ o valor da entrada *i* e *n* é o número de entradas.

2.2.2

Funções de ativação

A primeira função de ativação utilizada foi uma função degrau. Essa função tornava a saída do neurônio binária pois as respostas de neurônios biológicos são binários, no entanto a resposta biológica não corresponde apenas à ativação do neurônio mas também a sua frequência de ativação. A função de ativação foi então substituída por funções não binárias para permitir múltiplas repostas dos neurônios artificiais.

2.2.2.1

Função linear

A função linear é a função de ativação mais simples de ser usada, no entanto ela dificulta a obtenção de respostas não-lineares pela rede neural, e tem a forma

$$L = ax, \quad (8)$$

onde *L* é a saída da função linear, *x* é a entrada da função de ativação, nesse caso o valor do somatório mais o bias, “a” é uma constante que define a inclinação da reta. A função linear é apresentada na Figura 6.




Figura 6-Curva da função de ativação Linear

Atualmente a função linear é mais usada na camada de saída, pois tem simetria entre os valores positivos e negativos.

2.2.2.2

Função Sigmoid

A função sigmoide é a função de ativação mais comumente utilizada. Ela é bastante utilizada devido ao fato de ser não linear e ser facilmente derivada, o que facilita o processo de aprendizado por backpropagation. A função sigmoide (CHOLLET, 2017) é definida como

$$S = \frac{2}{1 + e^{-x}} - 1, \quad (9)$$

onde S é a saída da função sigmoide e x é a entrada da função. A figura 7 apresenta a função sigmoide.




Figura 7-Curva da função de ativação Sigmoide

2.2.2.3

Função ReLU

Outra função bastante utilizada atualmente consiste na função de unidade linear retificada (ReLU-Rectified Linear Unit). Esta função apresenta uma não linearidade devido a uma descontinuidade presente na função, dado que para valores de entradas menores que zero a saída é zero, e para valores maiores que zero a saída é linear, como descrito por (GLOROT, BORDES e BENGIO, 2011)

$$R \rightarrow \begin{cases} x > 0, & R = ax \\ x \leq 0, & R = 0 \end{cases} \quad (10)$$

onde R é a saída da função ReLU, x é a entrada da função e “a” é o coeficiente linear da função (comumente 1). A figura 8 apresenta a função ReLU.




Figura 8-Curva da função de ativação ReLU

O uso do bias determina a região de corte da função ReLU. A função ReLU possui a vantagem de não ativar todos os neurônios simultaneamente, tornando a rede mais robusta e o aprendizado mais fácil. No entanto ela gera o problema de *vanishing gradient*, que consiste no fato dos gradientes tenderem a zero. Esse problema levou ao desenvolvimento da próxima função de ativação.

2.2.2.4

Leaky ReLU

A Leaky ReLU é bastante parecida com a função ReLU, no entanto, caso o valor de entrada esteja abaixo de zero, o valor de saída passa a ser linear com uma inclinação bem próxima de zero. A função Leaky Relu (MAAS, HANNUN e NG, 2013) é definida por

$$LR \rightarrow \begin{cases} x > 0, & LR = ax \\ x \leq 0, & LR = bx \end{cases} \quad (11)$$

onde LR é saída da função Leaky ReLU, x é a entrada da função, “a” é o coeficiente da função linear superior e “b” é o coeficiente da função linear inferior. Geralmente “a” é 1 e “b” possui valor entre 0,1 e 0,001. Na figura 9 seguir pode ser vista a função Leaky ReLU.




Figura 9-Curva da função de ativação Leaky ReLU

2.2.3

Conexões

Os neurônios podem ser conectados de diversas formas dentro da rede neural. No entanto, neurônios como o apresentado na subseção anterior só podem ser conectados em redes *feedforward*, ou seja, redes sem realimentação. Isso se deve ao fato de o neurônio apresentado não apresentar *delay* (como o neurônio original de McCulloch e Pitts) ou não apresentar uma função de memória para armazenar estados anteriores do neurônio.

2.2.4

Passo

Em redes *feedforward*, os neurônios podem se conectar com todos os neurônios da camada anterior (*fully connected*) ou se conectar com apenas com um número limitado de neurônios. Caso cada neurônio se conecte com um número limitado de neurônios da camada anterior, geralmente essa ligação ocorre com os neurônios mais próximos. Essas ligações podem ocorrer com espaçamento maior que 1, ou seja, existe um passo (*stride*) maior que 1. O uso desse passo serve para filtrar os dados da rede, e reduzir o número de neurônios na rede, tornando-a assim mais rápida.

2.2.5

Padding

Outro fator importante quando o neurônio tem o número de conexões limitados é como as conexões ocorrem na borda da camada anterior. Em alguns casos é usado um preenchimento das entradas dos neurônios (*padding*), isso querendo dizer que são acrescentados entradas iguais a zero na bordas da imagem.

2.3

Redes Neurais Convolucionais Profundas

Uma rede neural é composta de uma ou mais camadas de neurônios. Caso a rede apresente apenas a versão moderna do neurônio de McCulloch, ela é conhecida como MLP. No entanto, diversas redes atualmente utilizam mais de um tipo de neurônio, como é o caso das redes convolucionais.

As redes neurais convolucionais são compostas em geral por três tipos de camadas, as camadas convolucionais, as camadas de *downsampling* e camadas de rede Perceptron. Além disso, quando a rede possui um número muito grande de camadas e neurônios elas são chamadas de redes profundas.

2.3.1

Camada Convolutiva

Uma camada convolutiva é composta de três dimensões, cada plano horizontal da camada (*channel*) sendo responsável por extrair um padrão da entrada. Para isso, cada neurônio deste plano possui o mesmo padrão de pesos (*kernel*). A aplicação da rede consiste na convolução do *kernel* sobre a entrada, formando o que é conhecido como *feature map*. Na figura 10 pode ser visto o processo de convolução.

$$\begin{array}{|c|c|c|c|c|} \hline 0 & 0 & 0 & 0 & 0 \\ \hline 0 & 1 & 1 & 1 & 0 \\ \hline 0 & 1 & 2 & 1 & 0 \\ \hline 0 & 1 & 1 & 1 & 0 \\ \hline 0 & 0 & 0 & 0 & 0 \\ \hline \end{array} \times \begin{array}{|c|c|c|} \hline 0 & 1 & 1 \\ \hline 1 & 1 & 0 \\ \hline 0 & 1 & 1 \\ \hline \end{array} = \begin{array}{|c|c|c|} \hline 4 & 5 & 3 \\ \hline 5 & 7 & 5 \\ \hline 4 & 5 & 3 \\ \hline \end{array}$$

Figura 10- Processo de convolução

Muitas vezes o *kernel* de uma rede é bidimensional, enquanto a entrada é tridimensional (como, por exemplo, os vários *feature maps* da camada convolucional anterior), e neste caso a entrada passa a ser o somatório dos *feature maps*.

2.3.2

Camada de *downsampling*

Comumente entre as camadas convolucionais encontram-se camadas de *downsampling*. Essas camadas são responsáveis por extrair informações dos *feature maps* e reduzir a quantidade de dados passados às camadas seguintes e assim o número de neurônios. Para isso, as camadas de *downsampling* em geral possuem *stride* maior que 1. Existem diversos tipos de camadas de *downsampling*, sendo as mais comuns as de média e a de máximo. Na figura 11 é demonstrado o processo de *downsampling* por máximo.




Figura 11 -Camada de downsampling usando a função de max pool

2.3.3

Aprendizado

O aprendizado da rede neural depende de dois fatores, do objetivo da rede e como ele é realizado, se é supervisionado ou não. O objetivo da rede, como já foi descrito anteriormente, pode ser reconhecimento de padrões, classificação ou regressão. Já a forma pode ser supervisionada, caso se tenha conhecimento da saída para um número específico de dados, ou não supervisionado, caso se espere que a rede extraia informações desconhecidas dos dados.

No caso do PIV, a rede deve ser capaz de reconhecer padrões de partículas e interpolar os dados para obtenção do deslocamento. Assim, o tipo de aprendizado a ser utilizado será o supervisionado.

2.3.4

Backpropagation

Para redes *feedforward* com aprendizado supervisionado e com o objetivo de interpolar os dados, o algoritmo de aprendizado mais utilizado é o *backpropagation*. Este algoritmo consiste em calcular o erro da rede para um *batch* de dados. Para isso é necessário primeiramente estabelecer a equação do erro a ser utilizada. A mais comum é o erro médio quadrático, dado por (SIDHU, 2019)

$$MSE = \sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}, \quad (12)$$

onde n é o número exemplos no batch de treinamento, i é o número do elemento de treinamento no batch, y_i é a resposta da rede para a entrada de posição i no batch, e \hat{y}_i é o valor esperado para a entrada de posição i .

Por meio da equação do erro é calculada a derivada do erro em relação aos pesos sinápticos. Nas equações a seguir é demonstrado o processo de derivação usando o erro médio quadrático e função de ativação sigmoide.

Expressão para a última camada:

$$\frac{dE}{dW_{j,t}} = (\hat{y}_i - y_i) \cdot y(1 - y)(Input_i) \quad (13)$$

Com a derivada parcial de cada peso é usado um fator de aprendizado alfa para corrigir o valor do peso de acordo com

$$W_{i,t+1} = W_{i,t} - \alpha \cdot \frac{dE}{dW_{i,t}} \quad (14)$$

2.3.5

Montagem de Rede Neurais

Uma técnica comum em redes neurais é o uso de várias redes neurais de forma combinada. Esse processo se dá por meio do treinamento de uma rede neural para obter uma informação específica e o uso de diversas redes para processar informações mais complexas. Um exemplo seria o uso de uma rede neural para reconhecer letras escritas à mão e outra rede para reconhecer o significado de palavras e frases que usam essas letras (GÉRON, 2017).

2.3.6

Cascata de Redes Neurais

A ideia por trás da cascata de rede neurais em níveis é que cada nível refine o resultado da rede anterior, a fim de que a cada nível o erro se reduza. Para tal, as redes do primeiro nível são treinadas com as imagens originais de antes e depois do movimento e com o valor de resposta esperado. O resultado final do primeiro nível passa a ser a média do deslocamento dessas redes. As imagens antes e depois do movimento são então deslocadas pelo valor encontrado no nível anterior, sendo metade desse valor na imagem anterior ao movimento e metade desse valor no sentido oposto na imagem depois do movimento. Então as redes do segundo nível são treinadas com essas novas imagens e com o deslocamento esperado menos o valor do deslocamento até então. Com isso a rede do segundo consegue refinar o resultado do primeiro nível. Esse processo pode ser repetido inúmeras vezes, sendo que a cada nível o erro determinístico da rede vai diminuindo. O resultado final da cascata consiste no somatório dos deslocamentos obtidos em cada nível.

Antes de se desenvolver o equacionamento da cascata é necessário desenvolver o equacionamento da medição de cada nível. A equação (15) apresenta a medição de uma única rede.

$$U_{ij} = U_{esp} + e_{ij} \quad (15)$$

onde U_{ij} é a medição da rede j do nível i da cascata, U_{esp} é a medição esperada e e_{ij} é o erro de medição da rede em i e j . Para o valor da medição em um nível tem-se

$$U_i = \sum_{j=1}^{n_i} \frac{U_{ij}}{n_{ij}} = \sum_{j=1}^{n_i} \frac{U_{esp} + e_{ij}}{n_i} = U_{esp} + \sum_{j=1}^{n_i} \frac{e_{ij}}{n_i} = U_{esp} + E_i \quad (16)$$

onde U_i é a medição do nível i e E_i é o erro médio do nível i . Para o primeiro nível, o valor de medição esperado é o deslocamento real U . Assim, o equacionamento para o primeiro nível é

$$U_1 = U + E_1 \quad (17)$$

Para o segundo nível da cascata deslocamento as imagens pelo valor encontrado no primeiro nível e tem-se que o valor de medição esperado é a diferença entre o valor real U e o valor de medição do primeiro nível, ou seja,

$$U_2 = (U - U_1) + E_2 = E_2 - E_1 \quad (18)$$

Para o terceiro nível e níveis seguintes tem-se que o deslocamento esperado é a diferença entre o deslocamento real e a soma dos deslocamentos dos níveis anteriores, com isso a equação fica

$$U_k = \left(U - \sum_{i=1}^k U_i \right) + E_k = E_k - E_{k-1} \quad (19)$$

Onde k é o nível da rede que se está calculando. Para o equacionamento da cascata tem-se

$$U_{casc} = U_1 + U_2 + \dots + U_m \quad (20)$$

onde U_{casc} é o valor da medição da cascata, e U_m é a medição do último nível da cascata. Substituindo os valores de medição de cada nível na equação anterior tem-se

$$U_{casc} = U + E_m \quad (21)$$

onde E_m é o erro do último nível da cascata. Para um nível da cascata reduzir a condição a seguir precisa ser satisfeita:

$$\frac{E_i}{E_{i-1}} < 1 \quad (22)$$

Sendo que estes valores de erro podem ser estimados através de um teste com deslocamentos conhecidos de imagens sintéticas.

2.4

Redes Neurais aplicadas a PIV

Os trabalhos (GRANT e PAN, 1995) e (GRANT e PAN, 1997) foram pioneiros no uso de redes neurais aplicadas a PIV. Naqueles trabalhos, duas redes neurais foram empregadas para a realização do processo de filtragem das imagens e para a estimação dos deslocamentos das partículas. As redes utilizadas nos trabalhos de Grant & Pan possuíam de 3 a 4 camadas e o método de aprendizado era não supervisionado, baseado no método de Kohonen (KOHONEN, 1982). A detecção do deslocamento das partículas era feita em imagens com dupla exposição, ou seja, os dois pulsos de iluminação do escoamento eram capturados em uma mesma imagem. Assim, uma mesma imagem continha as partículas em dois instantes de tempo diferentes. Em um terceiro trabalho de (GRANT, PAN, *et al.*, 1998) foi desenvolvida uma rede de Hopfield para recombinar imagens estereoscópicas de PIV. Nos

trabalhos do grupo de Grant & Pan, diversas dificuldades foram encontradas na implementação das redes neurais em conjunto com a técnica de PIV. Dentre essas dificuldades, destaca-se o número elevado de imagens necessárias para realizar o treinamento da rede. Além disso, os resultados descritos naqueles trabalhos mostraram que os métodos baseados em redes neurais apresentaram resultados sistematicamente inferiores aos métodos convencionais de PIV. Assim, o uso de redes neurais em PIV foi deixado de lado por alguns anos.

Com a melhoria do hardware e dos modelos de redes neurais para visão computacional, em especial com o uso de redes convolucionais, retomou-se o interesse pelo desenvolvimento novos métodos de PIV baseados em RNA. O primeiro trabalho de destaque desde aquele período é (RABAULT, KOLAAS e JENSEN, 2017), no qual foram desenvolvidos dois tipos de redes neurais para PIV, a saber: uma rede convolucional e uma rede MLP padrão. Ambas são treinadas de forma supervisionada por meio do algoritmo de *backpropagation*. O conjunto de dados de treinamento era composto por cerca de 600 milhões de pares de imagens sintéticas de PIV de formato 32x32 pixels. A rede convolucional proposta apresentava uma única camada convolucional com 512 kernels de 16x16 e profundidade aplicada com stride 2. Em seguida a rede apresentava 4 camadas totalmente conectadas. A segunda rede neural apresentava 6 camadas totalmente conectadas com função de ativação *Leaky ReLu*. Em ambas as redes o resultado foi inferior ao do software da LaVision, sendo que a rede MLP obteve um resultado um pouco pior que a rede convolucional. Nota-se que neste trabalho as imagens utilizadas no treinamento apresentavam pouca variação de deslocamento. Este fato restringiu a análise da rede, pois tende a ser o ponto principal saber como a rede trabalha com a deformação do padrão de partículas nas imagens.

No segundo trabalho, (LEE, YANG e YIN, 2017), foi proposta a utilização de redes convolucionais em cascata para a medição do deslocamento da partículas. O conceito da cascata consistia em realizar em cada nível a medição para uma magnitude de deslocamento. Assim, conforme o par de imagens é processado por diferentes níveis da cascata, sua medição vai sendo refinada. A cascata apresentada em (LEE, YANG e YIN, 2017) possuía 4 níveis, sendo os três primeiros com uma rede cada e o último com 3 redes em paralelo. A rede utilizada em cada nível possuía três camadas convolucionais intercaladas com camadas de *maxpooling* e com duas camadas totalmente conectadas. As redes são treinadas de forma supervisionada com o algoritmo de *backpropagation* e utilizando 800 mil imagens sintéticas. Essa rede apresentou melhores resultados que a do trabalho (RABAULT, KOLAAS e JENSEN, 2017). No entanto, ela apresenta um aumento significativo do erro quando se passa de imagem sintética para imagens reais. Esse erro apresenta de forma mais significativa nas regiões de maior deslocamento e com maior gradiente de deslocamento. O modelo

apresentado por Lee será melhor analisado nos capítulos seguintes, dado que serve como base para esta dissertação.

3

PIV com redes neurais – Implementação, validação e testes de modelo da literatura

Neste capítulo buscou-se reproduzir um modelo que é o estado da arte em termos de redes neurais convolucionais aplicadas a PIV. O objetivo é analisar os resultados obtidos com a ferramenta e, a partir daí, propor melhorias. Nesta etapa, escolheu-se utilizar como base o modelo de rede neural proposto no trabalho (LEE, YANG e YIN, 2017). Logo, um dos primeiros passos foi replicar o programa desenvolvido por Lee e co-autores. Para isso utilizou-se a linguagem de programação Python, ao invés da implementação original dos autores, que era baseada em MATLAB. Com esse programa repetiram-se os testes realizados no artigo de referência e realizaram-se novos testes, que geraram o artigo (CORREIA, DE PAULA e AYALA, 2019). Por meio da construção desse programa ganhou-se o conhecimento de como a rede convolucional opera, quais suas vantagens e desvantagens.

3.1

Descrição da Rede Convolucional

O método do trabalho de (LEE, YANG e YIN, 2017) consiste em uma cascata de redes neurais convolucionais. A cascata de redes empregada naquele trabalho possui uma arquitetura que pode ser ilustrada esquematicamente na Figura 13.




Figura 12-Rede Convolucional.

A rede possui como entrada duas janelas de interrogação de 64x64 pixels. Cada janela de interrogação é extraída de uma das imagens do par de imagens PIV. Assim, a entrada da rede possui dimensão de 64x64x2. A primeira camada consiste de uma camada convolucional

de $60 \times 60 \times 2 \times 20$, com *kernel* de tamanho $5 \times 5 \times 2$ e *stride* 1. A segunda camada consiste de uma camada de *maxpooling* com *kernel* 3×3 e *stride* 2, ficando assim com o tamanho $30 \times 30 \times 20$. A terceira camada é outra camada convolucional com *kernel* 5×5 , possuindo tamanho final de $26 \times 26 \times 50$. Depois, há mais uma camada de *maxpooling* com *kernel* 3×3 e *stride* 2, ficando com o tamanho $13 \times 13 \times 50$. A última camada convolucional possui *kernel* 4×4 e tamanho $10 \times 10 \times 100$. Finalmente, há mais uma camada de *maxpooling* com *kernel* 3×3 e *stride* 2, e tamanho $5 \times 5 \times 100$. Com isso, finaliza-se a parte de convoluções e de *pooling* e tem-se uma saída $2 \times 2 \times 100$.

As últimas camadas têm neurônios padrões em camadas totalmente conectadas, que recebem a saída de uma camada *flatten* que transforma o formato de saída da última camada de *downsampling* em um vetor. Para tanto, é aplicada uma camada *fully connected* com 500 neurônios e função de ativação ReLU, e em seguida uma camada *fully connected* com 2 neurônios e função de ativação linear para mapear o deslocamento das partículas em duas dimensões.

3.2

Descrição da Cascata de Redes Convolucionais

Com esse modelo de rede foi construída uma cascata de acordo com a figura a seguir.




Figura 13 - Diagrama da cascata de redes convolucionais

Nos três primeiros níveis, a cascata é composta de uma rede por nível, sendo o quarto nível da cascata composto por três redes em paralelo, e sendo a sua saída o valor de deslocamento médio das três redes. Este processo é usado para reduzir o erro das redes. O deslocamento final consiste no somatório do deslocamento de cada nível.

3.3

Descrição do Dataset

No treinamento realizado no trabalho de (LEE, YANG e YIN, 2017) adota-se um *dataset* de treinamento independente para cada nível da cascata. Esta também foi a metodologia adotada nesta seção do trabalho. A estratégia se diferencia daquela adotada no modelo

proposto em (SUN, WANG e TANG, 2013), onde foi utilizado um único *dataset* para todas as camadas, de modo que o treinamento de cada nível considerou a resposta do nível anterior. A Tabela 1 apresenta o deslocamento máximo, em *pixels*, das imagens do *dataset* de treinamento que foram utilizadas nesta etapa do trabalho. Os valores listados na tabela estão separados para cada nível da rede.

Tabela 1: Deslocamentos usados nas imagens do dataset de treinamento

Níveis	Deslocamento entre
Nível 1	-12 a 12 pixels
Nível 2	-5,0 a 5,0 pixels
Nível 3	-1,2 a 1,2 pixels
Nível 4	-0,1 a 0,1 pixels

3.4

Resultados

Para analisar o modelo desenvolvido por (LEE, YANG e YIN, 2017) e a implementação feita em Python, no âmbito deste trabalho, compararam-se os resultados obtidos por esses dois códigos com uma referência. A referência adotada neste trabalho foi um algoritmo de PIV tradicional, baseado em correlação cruzada e com correção da deformação das imagens, denominado PIV-WIDIM. Esse método é amplamente adotado na maioria dos softwares de processamento PIV e permite capturar deslocamentos de partículas, mesmo na presença de pequenos gradientes de velocidade. Nessas comparações, utilizou-se também o método original do trabalho de (LEE, YANG e YIN, 2017), denominado aqui como DCNN-Matlab. O método original está disponível online na plataforma GitHub¹.

3.4.1

Validação do programa em Python

O primeiro passo desta análise foi a validação da implementação feita em linguagem Python. Para isso, realizaram-se testes com imagens sintéticas de PIV. Adotaram-se nestes testes imagens de padrão de partículas com diâmetros na faixa entre 0,35 e 6 pixels, concentração de partículas de 0,001 a 0,1 ppp (partículas por pixel) e níveis de partículas perdidas (*out of plane*) de 0 a 0,1. Na Figura 14 pode ser vista a concordância com o deslocamento teórico em um dos estágios da cascata da rede. Nos gráficos, o eixo horizontal corresponde ao valor exato e o eixo vertical ao valor estimado com a rede neural.

¹ <https://github.com/yongleex/PIV-DCNN>

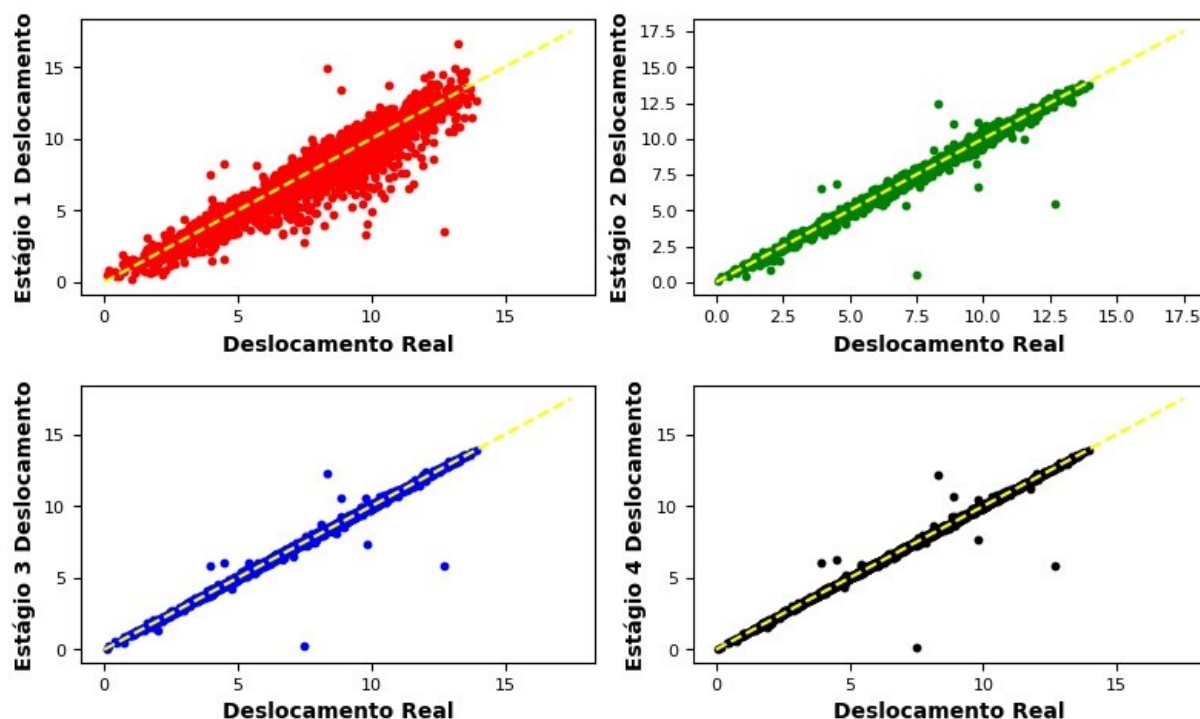


Figura 14 - Valor medido versus valor real em cada estágio da rede implementada em Python, com base no método proposto no trabalho de (LEE, YANG e YIN, 2017).

Os resultados da Figura 14 sugerem que a rede que foi implementada no presente trabalho funciona, aparentemente, bem e com poucos vetores espúrios. Em todos os estágios o valor médio da medição está próximo do valor correto (deslocamento medido próximo do deslocamento real), sendo que nos primeiros estágios a incerteza é bem maior, dado que a distribuição dos valores de deslocamento é dispersa em torno da linha ideal (tracejada). Na última camada da rede, observa-se que a maior parte dos vetores espúrios observados estão relacionados a imagens para as quais os primeiros estágios da cascata não são capazes de estimar corretamente o deslocamento. Assim, o erro se propaga até o último estágio e parece ser a causa dos vetores espúrios.

Na Figura 15, comparam-se os resultados da rede em Python com a implementação original feita no trabalho de (LEE, YANG e YIN, 2017), DCNN-Matlab, e o método de referência (PIV-WIDIM). Nesta figura, todos os três códigos mostram um baixo desvio em relação à curva ideal. Dentre os códigos, a rede em Python foi a que apresentou o maior número de vetores espúrios, enquanto que o PIV-WIDIM aparenta possuir menor incerteza, pois possui menor desvio em relação à linha ideal.




Figura 15 - Comparação entre os valores medido e reais dos três modelos

Para uma análise mais detalhada do desempenho dos códigos construiu-se o histograma do erro dos resultados obtidos com cada método, conforme mostrado na Figura 16. Nesta figura, pode-se observar que a rede em MATLAB e o método padrão apresentaram desvios similares, enquanto a rede implementada em Python apresentou uma dispersão do erro um pouco maior. É interessante notar que todos os histogramas apresentaram semelhanças com a distribuição gaussiana. Apesar dos desvios no modelo implementado em Python serem um pouco maiores do que aqueles observados nos outros métodos, os resultados apresentados até aqui servem para validar a implementação. Os resultados piores se devem aos vetores espúrios.

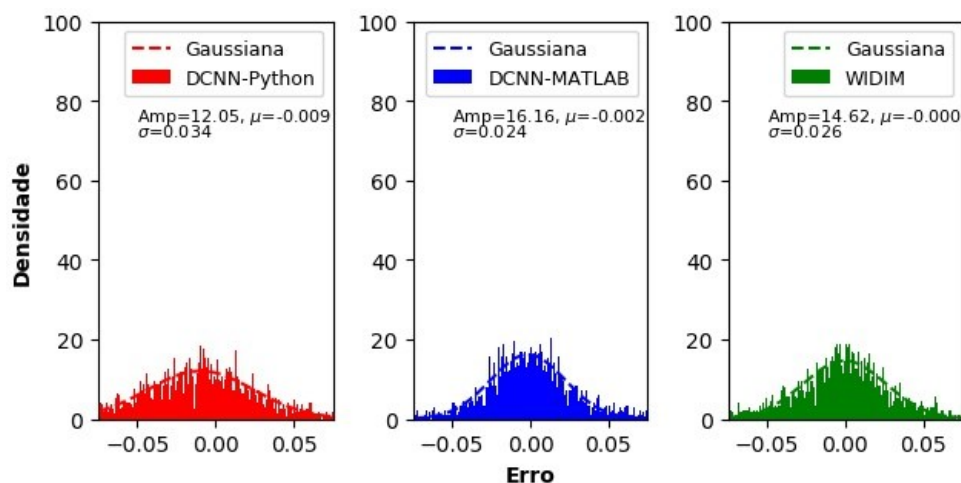


Figura 16- Histograma dos três modelos para um teste de validação

Com a validação da implementação em Python, buscou-se analisar de forma detalhada as principais limitações do método com relação a diferentes parâmetros das imagens de PIV. A partir destes resultados pretende-se propor melhorias incrementais de modo a melhorar a

resolução do método e consequentemente reduzir a incerteza na estimação dos campos de velocidade.

3.4.2

Análise de variação de diâmetro

Para realizar uma análise sobre como os diferentes métodos de estimação do deslocamento das partículas se comportam com a variação do diâmetro dessas partículas, foram utilizadas imagens com concentração constante de 0,05 ppp (partículas por pixel). Neste teste, a concentração de partículas perdidas por movimento fora do plano de medição (*out of plane*) foi desprezível. Além disso, não foram consideradas imagens com gradiente de velocidade significativo dentro das janelas de interrogação. Os resultados do teste são apresentados na Figura 17.

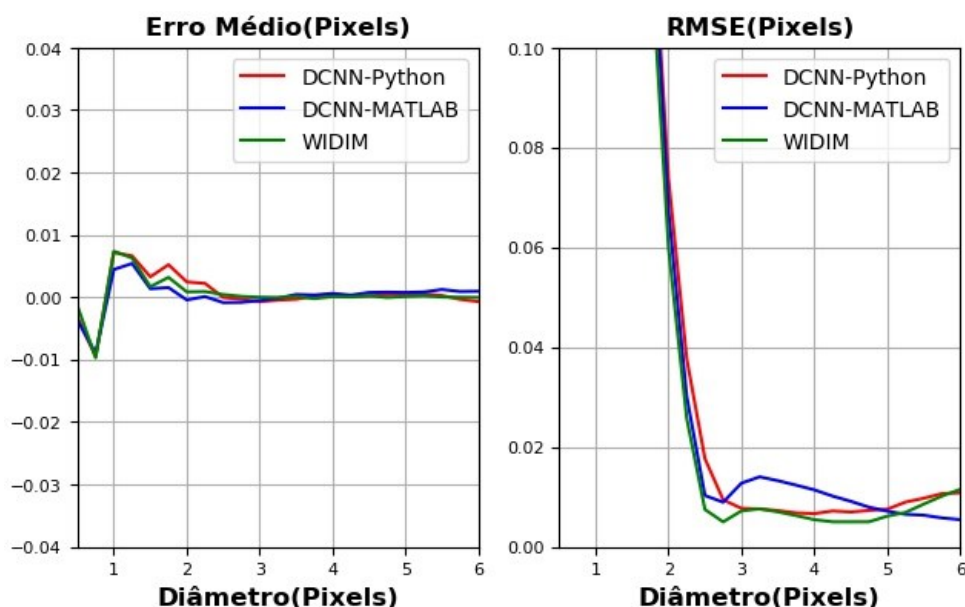


Figura 17 - RMSE e Erro Médio da análise da variação do diâmetro

O gráfico da direita mostra o comportamento do erro médio do tamanho das partículas nas imagens. Essa figura mostra se há alguma tendência na estimação do deslocamento das partículas. A figura mostra que, para diâmetros menores do que aproximadamente 2 pixels, o erro é elevado. Isso ocorre devido ao processo de discretização, ou seja, pela divisão do espaço em unidade inteiras de pixel, que no caso de partículas muito pequenas provoca perda de informação acerca da posição destas partículas. Isso ocorre porque a informação contida em pixels adjacentes ao centro da partícula é perdida. Os algoritmos de interpolação do máximo de correlação necessitam destas informações para estimação do deslocamento com resolução sub-pixel. Logo, partículas muito pequenas reduzem o número de dados empregados na correlação. Assim, é de se esperar que partículas com diâmetro da ordem de

2 pixels ou menos apresentem erros maiores. Isso é corroborado pelos resultados do gráfico de erro médio da Figura 17. Esse comportamento também pode ser observado no erro médio quadrático que é apresentado na Figura 17. Para partículas maiores, o erro tende a se manter razoavelmente estável. Entretanto, pode-se notar que a rede em Python mostra uma tendência de aumento do erro médio para partículas com diâmetros próximos dos valores máximos empregados no treinamento da rede, que no caso foi de 6 pixels. Apesar disso, nota-se que os 3 métodos têm comportamento semelhantes.

A Figura 18 mostra a probabilidade dos diferentes métodos de capturarem com sucesso o deslocamento das partículas, sem a ocorrência de *outliers*. O critério empregado para considerar uma medida como sendo um sucesso foi de que o erro na estimação do deslocamento deveria ser menor que 5 % do valor real. Novamente, pode-se observar que, no caso de partículas com diâmetro acima de 2 pixels, todos os códigos apresentam uma melhoria de desempenho. Isso sugere que, nesses casos há, de fato, uma limitação da técnica e deve haver múltiplas soluções para o problema, pois mesmo redes neurais não são capazes de prever corretamente o deslocamento das partículas.




Figura 18 - Probabilidade de Sucesso de acordo com o diâmetro das partículas

3.4.3

Análise de variação de concentração

Para analisar a influência da concentração de partículas nos resultados, utilizaram-se novamente imagens sintéticas onde o deslocamento exato era conhecido. Neste teste, o diâmetro das partículas foi fixado em 2,5 pixels e não foram incluídas quantidades significativas de partículas fora do plano. Somente foi variada a concentração com valores na

faixa entre 0,001 e 0,05 ppp (partículas por pixel). Para converter esses valores em partículas por janela de interrogação é necessário somente multiplicar o valor da concentração em ppp pela razão entre a área da janela de correlação e a área da partícula. As concentrações analisadas equivalem a valores de aproximadamente 0,2 a 0,4 partículas por janela de interrogação. Na Figura 19 apresenta-se o erro médio e o valor RMSE com a variação da concentração. Observa-se que baixas concentrações exibem uma tendência de aumento de erro. Isso sugere uma limitação inerente à técnica de PIV. Para concentrações acima de 0,01 ppp todos os códigos apresentam erro da ordem de 1/20 pixels, que é um valor típico obtido com técnicas convencionais de PIV (Raffel et. al., 2007). Cabe destacar ainda que, no caso do código de PIV em Python, nota-se um erro médio diferente de 0, o que indica uma pequena tendência na estimativa dos deslocamentos. Ainda assim, o valor da tendência é menor do que 1/20 px.




Figura 19 - RMSE e Erro Médio para análise de variação de concentração

A Figura 20 mostra a probabilidade de sucesso das medições com a variação da concentração das partículas nas imagens. Como era de se esperar, para baixas concentrações a probabilidade de acerto para baixas concentrações é muito baixa. Acima de 0,01, os três códigos apresentam resultados similares. Esses resultados são coerentes com aqueles apresentados na literatura e que estão compilados no livro de Raffel et al. (2007). Os testes sugerem que a técnica de PIV também está limitada a concentrações acima de valores da ordem de 0,01 ppp. As análises indicam que, para medições adequadas com a técnica de PIV, as imagens devem conter partículas com diâmetros acima de 2 px e concentrações acima

de 0,01 ppp. Isso é válido tanto para os algoritmos convencionais, como para métodos baseados em redes neurais.




Figura 20 - Probabilidade de Sucesso de acordo com a concentração

3.4.4

Análise em condições ideais

Nesta seção analisou-se como os diferentes métodos se comportam em condições ideais. Nestes testes adotou-se uma concentração fixa e igual a 0,05 ppp. Para esta concentração, analisaram-se os resultados em duas situações, sendo uma com o diâmetro das partículas de 2,5 pixels e outra com o diâmetro de 4 pixels.

O deslocamento estimado pelo deslocamento ideal é mostrado na Figura 21 para os dois diâmetros de partículas selecionados para a análise desta seção. A primeira figura ilustra os resultados obtidos com partículas de 2,5 pixels, enquanto a segunda figura mostra o caso com partículas de 4 pixels. Em ambos os casos os resultados formam linhas bem definidas em ângulos a 45°, o que demonstra qualitativamente a tendência de acerto do resultado.

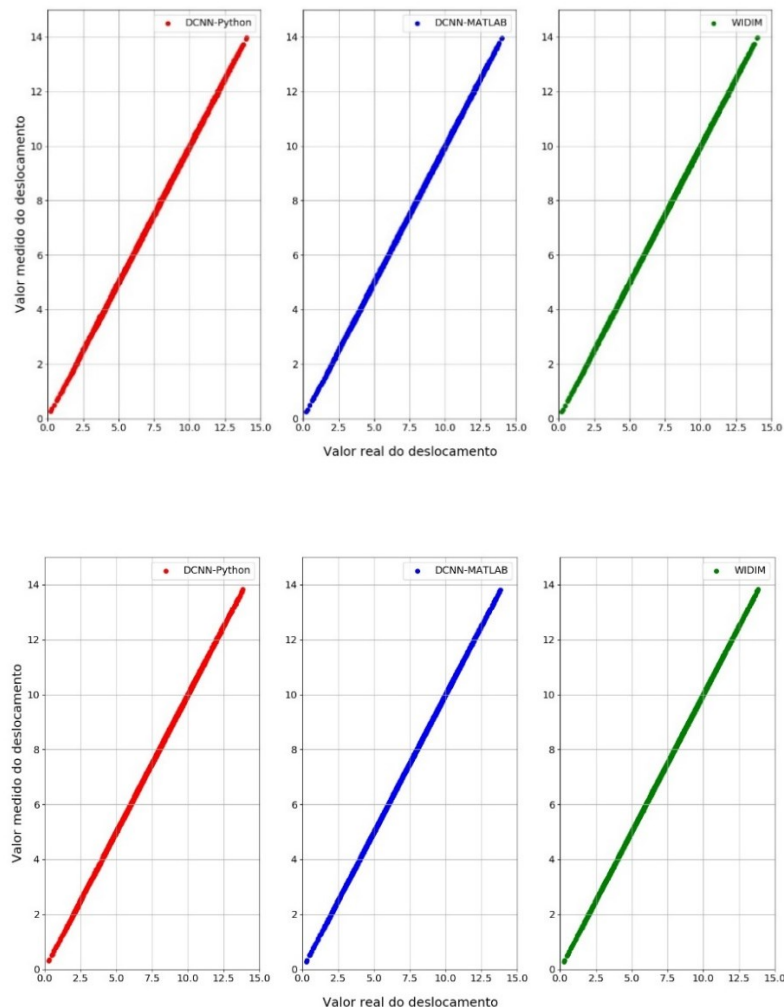


Figura 21 - Valor medido versus valor real para concentração de 0,05 ppp e diâmetros de 2,5 pixels (primeira figura) e 4,0 pixels (segunda figura)

Analisou-se também o histograma dos erros, conforme ilustrado na Figura 22. No caso de partículas com diâmetros de 2,5 pixels, os histogramas apresentaram uma distribuição normal. Observa-se uma boa aderência com a curva gaussiana que foi ajustada à distribuição dos dados. No caso com partículas de diâmetro de 4 pixels, o espalhamento dos histogramas parece ser consistentemente menor. No entanto, a rede em Python apresenta uma tendência clara de erro em torno de valores de $\pm 0,025$ pixel. A razão para isso não é muito clara. Na rede em Matlab, também há uma tendência de acúmulo de erros em valores próximos de 0,01 pixel. Conjectura-se que isso possa estar relacionado ao número de imagens utilizadas para o treinamento da rede e às condições de erro obtidas no treinamento. Em todos os casos essa tendência foi inferior à resolução dos métodos, que foi de aproximadamente 1/20 pixels.

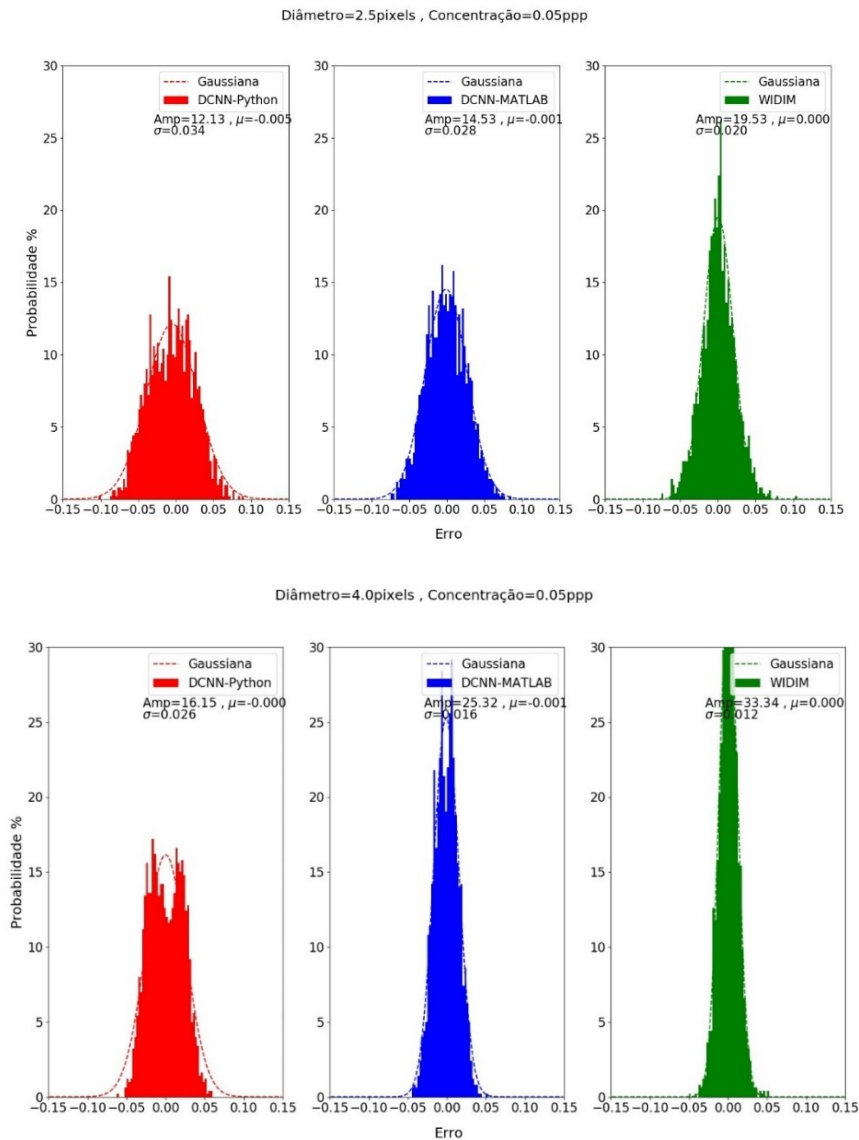


Figura 22 - Histogramas do erro para concentração de 0,05ppp e diâmetros de 2.5 (figura superior) e 4.0 (figura inferior) pixels

Uma última análise deste teste foi a avaliação dos erros médio e RMSE para diferentes valores de deslocamento das partículas. Os resultados são apresentados na Figura 23. Nota-se que em todos os casos o erro médio ficou centralizado em torno de zero e as flutuações foram da mesma ordem de magnitude. No caso do RMSE os valores de erro apresentam oscilação. Há uma clara tendência de redução do erro em torno de deslocamentos com valores de pixels inteiros e aumento em torno de deslocamentos de 0,5 pixel. É interessante notar que isso ocorre tanto no PIV tradicional como no PIV baseado em redes Neurais. Resultados similares foram relatados no trabalho de Lee et al. (2017).

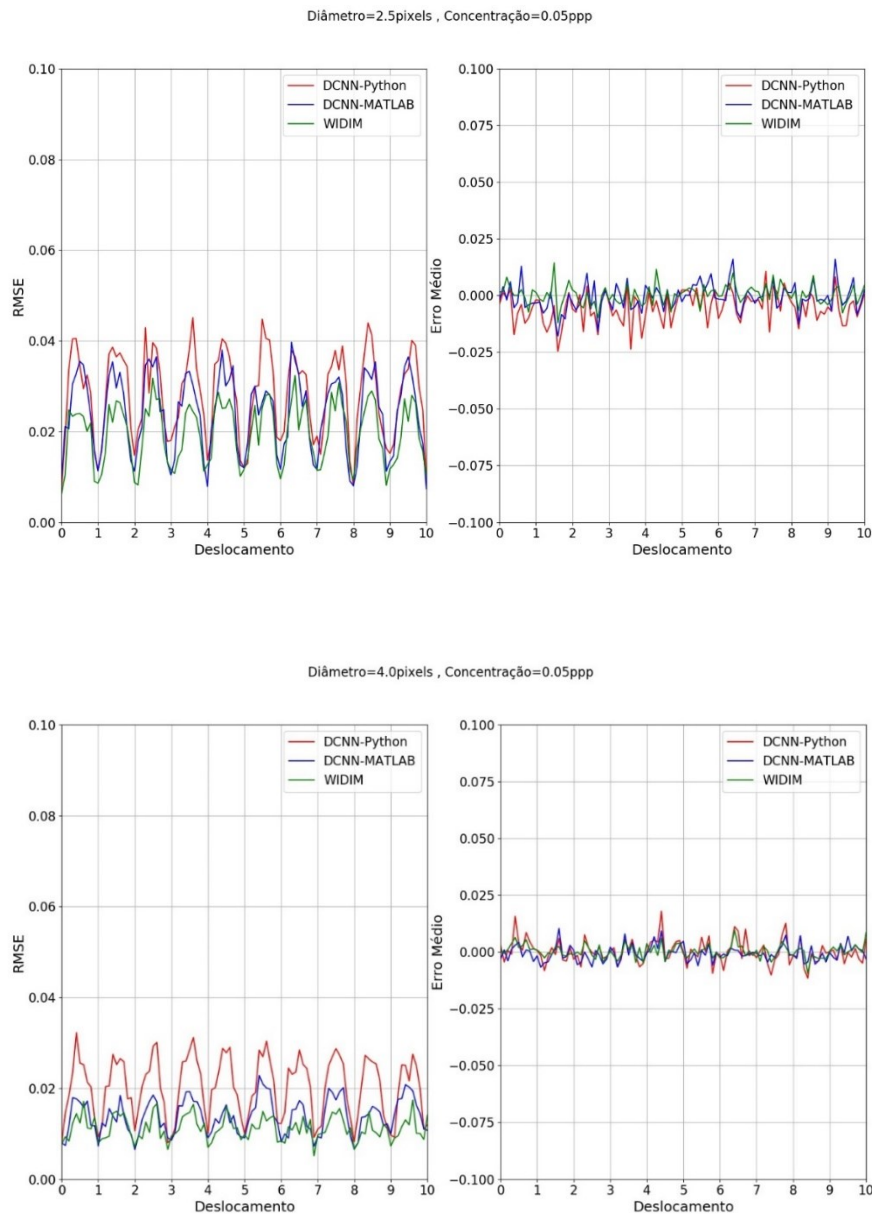


Figura 23 - Análise RMSE e Erro Médio para concentração de 0,05ppp e diâmetros de 2.5 e 4.0 pixels respectivamente

Os resultados mostrados até aqui serviram para validar os métodos. Esse tipo de análise foi também empregada na validação do trabalho original de Lee et al. (2017). A aplicação do método em imagens reais foi o último teste apresentado naquele trabalho. Para isso foram escolhidas imagens desafiadoras², em especial o caso de jato turbulento. Os resultados sugerem que o método de rede neural obteve valores de deslocamento sistematicamente menores do que aqueles fornecidos por algoritmos convencionais de PIV baseados em correlação cruzada e correlação cruzada com deformação de janela.

² <http://pivchallenge.org>

Na Figura 24 compararam-se os deslocamentos obtidos com a rede em Python e o WIDIM para o caso do jato turbulento que também foi analisado no trabalho de Lee et al. (2017). A diferença entre os resultados da rede em Python e do WIDIM também é apresentada na figura. Nota-se que, no caso da rede neural, há uma subestimação nos valores de deslocamento e há uma maior predominância de oscilações nos resultados. Isso sugere uma maior concentração de vetores mal processados (com valores de erro maiores do que 5 %). Como não existem valores exatos para os deslocamentos deste caso, fica impossível verificar se de fato esse é o caso. No entanto, como as imagens de PIV foram extensamente validadas na literatura, julga-se que essa diferença seja devida a erros no processamento com as redes neurais. Ainda de acordo com os resultados, observa-se que as maiores diferenças são observadas próximas à saída do jato, que na imagem corresponde ao local onde se observam os maiores deslocamentos com o algoritmo WIDIM.




Figura 24 - Jato Turbulento PIV challenge

Com vários pares de imagens disponíveis sobre esse jato foi analisado o comportamento do erro médio e do RMSE de acordo com o deslocamento das partículas, como mostrado na Figura 25. Neste caso, observa-se uma diferença sistemática entre os deslocamentos estimados com o método tradicional e a rede neural. Além disso, nota-se um aumento considerável do erro RMSE entre as medições com o aumento dos deslocamentos. As razões para isso são investigadas nas seções a seguir.




Figura 25 - Erro médio e RMSE para variação de deslocamento no jato turbulento

3.4.5

Análise de erro para imagem com gradientes

Para buscar possíveis fontes de erro na estimação do deslocamento das partículas em condições reais, foram analisadas imagens sintéticas com diferentes gradientes de velocidade. Neste teste, gradientes de velocidade constantes foram sobrepostos ao deslocamento das partículas na geração das imagens sintéticas. Nos testes foram utilizadas imagens contendo partículas de diâmetro de 2,5 pixels e com concentrações de 0,05 ppp.

Na Figura 26 é apresentado o valor do RMSE e do erro médio para diferentes gradientes. Cabe ressaltar que o gradiente é definido como a diferença de deslocamento horizontal entre dois lados (superior e inferior) de uma janela de interrogação. A figura mostra que o erro médio é próximo de zero e o RMSE varia linearmente com o gradiente. Isso ocorre tanto para o método de PIV tradicional como para a rede neural. Isso mostra que, de fato, na média, os algoritmos de deformação de janela reduzem a ocorrência de erros sistemáticos nas medições devido à presença de gradientes de velocidade. Entretanto, a presença destes gradientes dificulta a medição das flutuações instantâneas de velocidade.






Figura 26 - RMSE e erro médio para variação de gradiente


Com os mesmos dados utilizados no teste anterior avaliou-se a variação do erro com o gradiente e com o deslocamento das partículas. Para isso, subdividiram-se os resultados em grupos contendo gradientes lineares fixos em 0, 1, 3 e 5 pixels e os resultados são apresentados nas Figura 27(a),(b),(c) e (d) , respectivamente. Pode ser visto que em todos os casos o erro médio oscila em torno de zero para qualquer gradiente. O aumento das oscilações está associado a um aumento das flutuações, que é observada nos gráficos de RMSE. Nota-se que o gradiente faz com que o erro RMSE aumente com o deslocamento das partículas. Esse comportamento não é observado para gradientes nulos. Isso é observado tanto no método de PIV tradicional como na rede neural.




(a)



(b)



(c)



(d)

Figura 27 - RMSE e erro médio para diferentes gradientes e deslocamentos

Para se observar a influência de gradientes não lineares na resposta de cada modelo, realizaram-se testes com imagens sintéticas contendo oscilações periódicas de deslocamento das partículas. A frequência espacial dessas oscilações era conhecida e variou entre 0 e 0,025 comprimentos de ondas/pixel. Esse teste consistiu em 26 pares de imagens de tamanho 1000x1000. Cada par de imagens continha um número inteiro de comprimentos de ondas, assim tinha-se imagens desde 0 ondas por mil pixels a 25 ondas por mil pixels. As imagens foram subdivididas em janelas de interrogação de 64x64 pixels, de modo que no total foram feitos 13416 testes para cada frequência. Sabendo o deslocamento real e o valor obtido foi possível calcular o erro para uma determinada frequência.

Na Figura 28 pode ser visto o valor do ganho (definido como amplitude estimada/amplitude ideal) e do erro RMSE para diferentes frequências de oscilação. Para generalizar os resultados, optou-se por mostrar o eixo das frequências das ondas normalizado pelo tamanho da janela de interrogação. Observa-se que o ganho cai com o aumento da frequência espacial e que a rede em Python e o método padrão são aqueles que apresentam frequências de corte mais baixas (-3 dB ou ganho de 0,707). Nos dois casos o corte foi observado para valores de janelas normalizadas de aproximadamente 1,4. Para os valores de RMSE os resultados são similares na faixa de janelas normalizadas entre 0 e 1. Acima disso, observa-se um rápido aumento do erro da rede em Python. É interessante destacar que as imagens de PIV que foram processadas no método tradicional possuem janelas de interrogação com tamanho 2 vezes menor do que as janelas empregadas na análise com as redes neurais. Logo, a comparação dos resultados em termos absolutos indica que as redes neurais apresentam queda de ganho similar ao método WIDIM para oscilações com o dobro do comprimento de onda.




Figura 28 - Teste do seno

O último teste para gradiente consistiu em comparar os deslocamentos estimados pela rede em Python e pelo WIDIM a partir de imagens sintéticas de jato laminar. Os resultados são apresentados na Figura 29. As figuras indicam que as diferenças mais acentuadas são observadas na saída do bocal, onde estão localizados os maiores deslocamentos e aonde há oscilação espacial com menor comprimento de onda. O erro máximo esperado deveria ser 0.05 pixel enquanto que o erro máximo obtido foi cerca de 5 vezes maior, o que está muito acima da resolução esperada para esses métodos. Os resultados reforçam as observações feitas anteriormente para o jato turbulento.




Figura 29 – Campo de deslocamento de Jato Laminar

3.5

Considerações para o aprimoramento de modelos

Os resultados apresentados neste capítulo mostram que as redes neurais analisadas no âmbito deste trabalho, de fato, são capazes de estimar o deslocamento de partículas. No entanto, a metodologia proposta no trabalho de Lee apresenta erros sistemáticos com relação aos métodos tradicionais na estimação de deslocamentos de partículas em imagens reais. Aparentemente, o método de Lee et al. (2017) exhibe maior incidência de vetores espúrios do que o método tradicional. Observou-se que a presença de gradientes constantes de deslocamento não induz erros sistemáticos nas medições, mas esses gradientes causam aumento do erro RMSE, ou seja, aumentam a incerteza de medição. Na presença de gradientes não constantes, notou-se que, além de um aumento do erro médio quadrático, há também uma tendência na estimação do deslocamento. Os testes com flutuações espaciais de deslocamento de diferentes comprimentos de onda sugerem que o tamanho da janela de interrogação é um fator limitante ao método proposto no trabalho de Lee et al. (2017). A princípio, a redução do tamanho das janelas de interrogação é uma tarefa simples de ser corrigida. No processamento de PIV tradicional é comum o uso de estratégias que permitem variar o tamanho das janelas de interrogação para facilitar o processamento. Cabe ressaltar também que, no caso de processamento PIV com os métodos tradicionais, considera-se que as janelas de 64x64 pixels empregadas no trabalho de Lee et al. (2017) apresentam-se sobre dimensionadas. Na prática, utilizam-se janelas de 16x16 pixels e em casos extremos até 8x8 pixels. Logo, a redução do tamanho das janelas de interrogação é um desdobramento natural

do trabalho de Lee et al. (2017). No entanto, existem dificuldades práticas ao treinamento das redes com diferentes tamanhos de janelas. A principal é que o número de graus de liberdade do problema torna-se muito elevado, de modo que o treinamento da rede se torna uma tarefa mais custosa do ponto de vista computacional. Além disso, todos os possíveis cenários devem ser cobertos no treinamento, o que é importante para obter menor erro na estimação dos deslocamentos, principalmente nos primeiros estágios da cascata. Os fatores expostos contribuem para que as redes percam robustez e apresentem maiores erros em imagens reais. Conclui-se então que há fatores limitantes ao uso sistemático de neurais em algoritmos de processamento para PIV, o que enseja oportunidades de melhorias.

Em situações ideais, tanto o método tradicional como método o baseado em redes neurais apresentaram erros aleatórios da mesma ordem de grandeza. Logo, não é claro se existe de fato uma limitação à resolução do método devido à discretização das imagens das partículas ou se essa limitação se deve somente aos métodos utilizados. Esse tópico é menos claro e será investigado no próximo capítulo.

Com base nos resultados observados até aqui, decidiu-se combinar estratégias, de modo a conferir maior robustez e flexibilidade e reduzir incerteza nas medições de PIV.

4 Resultados

Foram testados diferentes arranjos e combinações de métodos da literatura para melhorar o processamento com a rede neural. Buscou-se reduzir as incertezas das medições, aumentar a flexibilidade e robustez e reduzir os desvios sistemáticos. Neste capítulo são descritos os resultados obtidos com essas diferentes estratégias.

4.1

Modelo Híbrido Correlação Cruzada – Rede Convolutacional (Rede64 Lee)

No capítulo 3 mostraram-se algumas limitações do método de PIV proposto no trabalho de Lee et al. (2017). Uma dessas limitações era o fato da rede ser treinada para uma faixa máxima de deslocamentos. O fato da rede neural ter que ser capaz de resolver todos os deslocamentos possíveis aumenta a quantidade de casos que precisam ser incluídos no treinamento e dificulta a inclusão de diversas variações de parâmetros das imagens reais de PIV no treinamento. Para restringir a faixa de deslocamentos da rede e manter a generalidade do método, buscou-se combinar redes neurais com métodos já estabelecidos de correlação cruzada. O método de correlação cruzada com múltiplos passes não possui uma limitação de deslocamento máximo tão restrita como a rede, além de ser mais rápido. Manteve-se a rede neural para o processo de estimação de deslocamento subpixel.

4.1.1

Arquitetura

A proposta nesta seção é de uma arquitetura em cascata, onde o primeiro nível corresponde ao processamento das imagens através da correlação cruzada e o segundo nível é composto por redes neurais com estrutura similar àquela do trabalho de Lee et al. (2017). Assim, a ideia é resolver de maneira grosseira os deslocamentos com os métodos convencionais de PIV e empregar a rede neural para substituir o algoritmo de detecção de deslocamentos com resolução de sub-pixel. Inicialmente continuou-se com janelas de 64 pixels. Por isso o algoritmo proposto nesta seção foi denominado de Rede64 Lee. A rede adotada é composta de duas camadas convolucionais de *kernel* 5x5 e com 20 e 50 de profundidade, respectivamente, e uma camada convolutacional de *kernel* 4x4 e profundidade

100. As camadas de *maxpooling* entre as camadas convolucionais possuem *stride* 2 e não têm *padding*. Essas camadas são seguidas por outras duas camadas *fully connected*, sendo a primeira com 500 neurônios com função Relu e a segunda com 2 neurônios e função de ativação linear.

4.1.2

Dataset

O conjunto de dados utilizados para treinamento da rede é composto de 1 milhão de pares de imagens com deslocamentos limitados entre 1,0 e -1,0 pixel. Além disso o treinamento ocorre através de mini-batch de 100 pares de imagens. A rede é treinada de forma similar à de Lee, onde cada camada tem seu próprio *dataset* para cada faixa específica de deslocamentos. No modelo desta seção utilizou-se somente um único *dataset*, pois só há uma única camada de rede. Além disso, a rede foi treinada com gradientes de velocidade baixos, de até 10 % do deslocamento máximo, que no caso equivalem a mais ou menos 0,1 pixel. O gradiente considerado foi baixo, porque o algoritmo convencional de detecção do deslocamento já inclui deformação de janelas. Portanto, a rede só precisa lidar com gradientes residuais. Esse é o gradiente residual máximo considerado após o uso da correlação cruzada com deformação de imagens. No treinamento da rede é usada taxa de aprendizado de 0,0001 por 10 épocas do *dataset* e depois por duas com taxa de 0,00001.

4.1.3

Resultados dos Testes de Validação

Alguns testes iniciais foram realizados para verificar se havia incompatibilidade entre a rede convolucional e a saída do método de PIV tradicional, sem o algoritmo de interpolação sub-pixel, uma vez que a rede é treinada de maneira independente.

O primeiro teste consiste na análise do deslocamento medido pelo real deslocamento das partículas. O teste é realizado na Rede64 Lee e comparado ao resultado do algoritmo de referência WIDIM. Para a realização do teste foram usadas partículas com diâmetro de 3 pixels e concentração entre 0,01 ppp a 0,04 ppp. O resultado da Figura 30 mostra que o método híbrido é capaz de estimar o deslocamento das partículas. A curva de resposta do método híbrido e da referência apresentam comportamento similar.




Figura 30 – Deslocamento mensurado x Deslocamento real das partículas

A Figura 31 mostra os valores de erro médio e erro médio quadrático (RMSE) da Rede64 Lee e da referência WIDIM. Observa-se que o RMSE de ambos os métodos apresenta oscilação com valores maiores em deslocamentos com fração próxima de 0,5 e menores em deslocamentos próximos de pixels inteiros. Isso também havia sido observado anteriormente. É interessante notar que os erros RMSE dos dois métodos têm amplitudes similares. No capítulo anterior foi notado que o erro RMSE era ligeiramente menor no método WIDIM. Entretanto, nota-se uma pequena tendência na estimação dos deslocamentos médios do caso com a rede híbrida. Esse erro é pequeno ($\sim 1/200$ px) mas é perceptível na análise.




Figura 31 – RMSE e Erro Médio (Rede64 Lee)

A distribuição dos erros em torno do valor médio é ilustrado nos histogramas da Figura 32. Nesta figura observa-se que Rede64 Lee e o WIDIM apresentaram distribuição em forma de gaussiana. É interessante notar aqui uma melhoria de desempenho em relação aos testes do capítulo anterior. A Rede64 Lee apresenta resultados muito similares aos obtidos com o WIDIM, possuindo uma incerteza similar ao WIDIM, se não fosse pela tendência observada

no erro médio. De qualquer maneira, os resultados sugerem que a simples substituição dos estágios mais grosseiros da rede neural por métodos de PIV tradicionais gerou uma melhoria considerável nos resultados da rede neural. Quando se comparam os resultados da Rede64 com o método tradicional ainda não se observam ganhos de desempenho.




Figura 32 – Histograma do Erro. Gráfico da esquerda - Rede64 Lee; gráfico da direita (WIDIM)

4.1.4

Teste de Robustez da Rede64 Lee

É importante avaliar como o método se comporta quando submetido a diferentes condições de medição. Isso é analisado nesta seção, onde observou-se o desempenho da Rede64 Lee para imagens contendo partículas de diferentes diâmetros e concentrações.

Na Figura 33 pode ser visto que a Rede64 Lee e a referência atingem 100 % de probabilidade de sucesso na estimação de deslocamentos para partículas com diâmetros maiores do que aproximadamente 2,5 pixels. Essa probabilidade se mantém até próximo de 6 pixels, que é o diâmetro máximo utilizado no treinamento da Rede64 Lee. No limite da faixa de treinamento a rede exibe uma queda de desempenho. Os resultados da Rede64 Lee são similares aos observados anteriormente e não demonstram nenhuma perda de desempenho significativa com relação ao diâmetro das partículas.

A análise do erro médio quadrático (RMSE) e do erro médio, apresentada na Figura 34, mostra que a Rede64 Lee apresenta resultado ligeiramente pior que o WIDIM com relação ao erro médio. Já o RMSE tem comportamento similar nos dois métodos. É interessante notar que o erro médio do método híbrido apresenta comportamento similar àquele obtido pela rede Python nos testes de validação na Figura 17. Isso sugere que esse erro ainda é resquício da

implementação e do treinamento da rede em Python e não tem relação com a combinação dos métodos.




Figura 33 – Probabilidade de sucesso de medição por diâmetro de partícula (Rede64 Lee).




Figura 34 - RMSE e Erro Médio por diâmetro de partícula (Rede64 Lee)

A influência da concentração de partículas na probabilidade de sucesso das medidas é analisada na Figura 35. Para este teste o diâmetro das partículas foi mantido constante e igual a 3 pixels. Nessa condição variou-se a concentração na faixa entre 0,002 ppp e 0,1 ppp. Os resultados mostram que as duas estratégias possuem comportamento similar com relação à concentração de partículas. Nos dois casos a probabilidade de sucesso cai bastante quando a concentração fica abaixo de 0,005 ppp (~1 partícula por janela de interrogação). Logo, nota-se que essa é uma limitação da técnica e a combinação dos métodos não teve influência na sensibilidade com relação a este parâmetro.




Figura 35 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64 Lee)

O comportamento do erro médio e RMSE com a concentração de partículas é avaliado na Figura 36. A análise do erro só é feita para concentrações que atingem probabilidade de sucesso de 100 %. Os valores RMSE obtidos com os dois métodos foram bem próximos para concentrações acima de 0,015 ppp. Para concentrações mais baixas, próximas da faixa limite, a Rede64 Lee apresentou valores RMSE mais elevados. O valor do erro médio não apresentou variações significativas com a concentração e a tendência similar àquela exibida pela Rede64 Lee se manteve em toda a faixa analisada.




Figura 36- RMSE e Erro Médio para diferentes concentrações de partículas (Rede64 Lee)

4.1.5

Considerações acerca da Rede64 Lee

Nesta seção 4.1 buscou-se avaliar o resultado da combinação do método convencional de PIV e métodos baseados em redes neurais. Na proposta, os métodos convencionais, que possuem reconhecida flexibilidade e robustez, foram empregados para a estimação de deslocamentos grandes e com resolução da ordem de pixels, enquanto as redes foram empregadas em um estágio final, somente para a estimação do deslocamento com resolução sub-pixel. Os resultados mostram uma melhoria significativa de desempenho em relação ao método original proposto no trabalho de Lee et al. (2017). O desempenho obtido foi similar ao de métodos convencionais baseados em regressões gaussianas. No entanto, observou-se uma pequena tendência na estimação dos valores médios de deslocamento. Além disso, nada foi feito aqui para reduzir o erro devido aos gradientes não uniformes de velocidade dentro das janelas de interrogação.

4.2

Modelo híbrido com rede neural baseada no trabalho de Sun et al. (2013)

Nesta seção buscou-se revisitar uma proposta feita no trabalho de Sun et al. (2013), onde cada camada da rede era treinada com os resultados da camada anterior. Isto difere da proposta testada anteriormente, onde o treinamento de cada camada era independente. A ideia é avaliar o desempenho dessa mudança nos resultados.

4.2.1

Arquitetura

A arquitetura usada é similar à da seção anterior, com exceção da primeira camada *fully connected*, que passou a ter função de ativação Leaky ReLU no lugar da função ReLU, no caso do treinamento ser realizado como sugerido no trabalho de Sun et al. (2013). Foi realizada essa substituição para evitar o problema de *vanishing gradient*.

4.2.2

Dataset

O *dataset* de treinamento é composto por 1 milhão de imagens com deslocamento entre -10 e +10 pixels. As imagens passam pelo processo de correlação cruzada, onde o deslocamento da ordem de pixel é estimado. As imagens deslocadas do valor estimado pela correlação cruzada são fornecidas como entradas para a rede neural, de modo que o deslocamento máximo esperado é de $\pm 0,5$ pixel. A rede então é treinada com essas imagens.

O número de repetições e valores de taxa de aprendizado da rede são os mesmos descritos na seção anterior.

4.2.3

Resultados dos testes de validação

No teste de deslocamento estimado comparado ao deslocamento real, todos os processos apresentam resultados parecidos, conforme ilustrado na Figura 37. Os resultados mostram que o processo da Rede64 Sun também é capaz estimar o deslocamento das partículas de maneira similar ao método convencional e à Rede64 Lee. Logo, não se verificou problemas na compatibilização dos dados e imagens de saída do PIV convencional para a Rede64 Sun.

A Figura 38 mostra uma comparação dos valores de erro obtidos pelos diferentes métodos. Nota-se aqui que os valores RMSE fornecidos pela Rede64 Sun são inferiores àqueles obtidos com a Rede64 Lee e com o WIDIM. No erro médio a Rede64 Sun apresenta um offset muito pequeno, da ordem de 1/100 px. Os resultados sugerem um desempenho melhor do método híbrido quando foi incluída, no treinamento da rede, a saída do método PIV convencional. Cabe ressaltar que essa redução na tendência e no erro foi obtida com o mesmo número de imagens do *dataset* de treinamento da rede. Logo, observa-se uma melhoria de desempenho da Rede64 Sun, também no que diz respeito ao treinamento.




Figura 37-Deslocamento estimado x deslocamento real (Rede64 Sun)

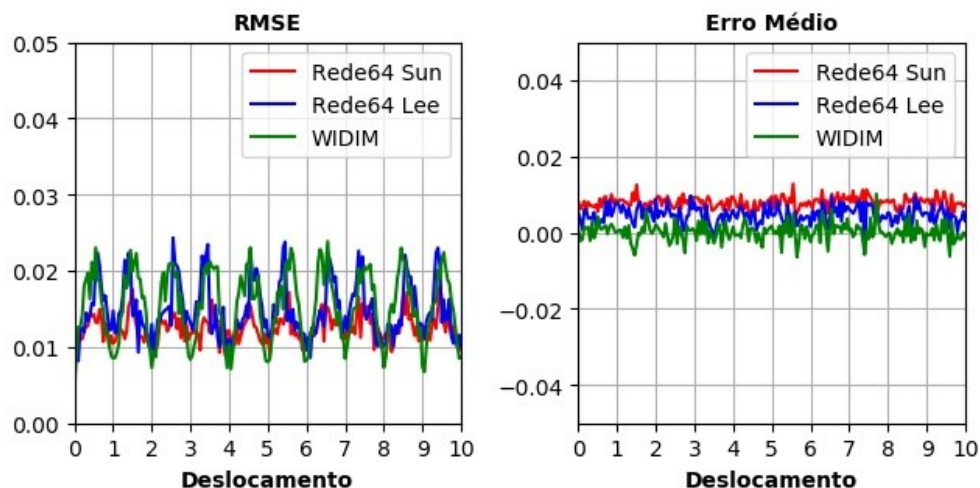


Figura 38 - RMSE e Erro Médio (Rede64 Sun)

Os histogramas de erro apresentados na Figura 39 demonstram que a Rede64 Sun apresenta uma melhoria significativa em relação aos métodos WIDIM e Rede64 Lee. Nota-se um claro aumento na curtose na curva, o que implica em redução do desvio e consequentemente em redução da incerteza das medições. De acordo com o teste, o pico do histograma da Rede64 Sun atinge o dobro do valor do WIDIM, com metade do desvio padrão.

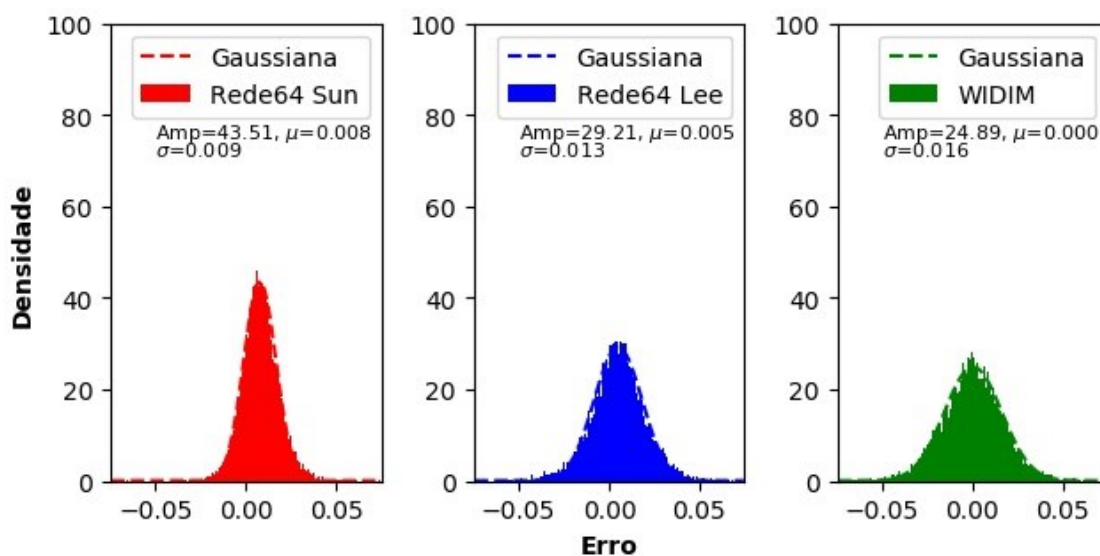


Figura 39- Histograma do Erro (Rede64 Sun)

Nos testes de robustez avaliou-se a influência do diâmetro e da concentração de partículas nos resultados. Na Figura 40, mostra-se o resultado do teste de probabilidade de sucesso com a variação de diâmetro das partículas. Observa-se que os métodos apresentam comportamento similar. No caso da Rede64 Sun, observa-se uma melhoria de desempenho em casos próximos ao diâmetro máximo utilizado no treinamento da rede. Isso sugere que

essa rede apresenta menores taxas de falha na faixa próxima ao limite de treinamento da rede.




Figura 40 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64 Sun)

A variação dos valores RMSE e dos erros médios de acordo com o diâmetro das partículas pode ser visto na Figura 41. Na escala analisada o erro RMSE apresenta comportamento similar entre os 3 métodos analisados. Já o erro médio apresenta melhoria significativa na Rede64 Sun quando comparado com a Rede64 Lee. Além disso, observa-se que os erros médios do WIDIM e da Rede64 Sun são similares. Isso mostra que, se havia alguma tendência nos resultados que era induzida pela combinação do método convencional com o treinamento independente da rede, isso foi suprimido quando incluíram-se no treinamento as informações da correlação cruzada.




Figura 41 - RMSE e Erro Médio por diâmetro de partícula (Rede64 Sun)

O teste de probabilidade de sucesso para variação de concentração de partículas Figura 42 demonstra que a Rede64 Sun é similar ao método WIDIM e que casos com concentrações abaixo de 0,005 px (aproximadamente 1 partícula por janela de interrogação) têm probabilidade de acerto baixa. Neste teste, o diâmetro das partículas foi constante e igual a 3 pixels. Cabe ressaltar que o bom desempenho dos métodos em condições de concentrações tão baixas só é obtido porque as imagens utilizadas nos testes são ideais em termos de partículas fora do plano e ruído. Em casos reais espera-se que a probabilidade de acerto fique próxima de 100 % somente para concentrações significativamente mais altas.

Ainda sobre os testes de variação de concentração das partículas, analisaram-se o RMSE e os erros médios. Os gráficos da Figura 43 mostram que a rede Rede64 Sun e o WIDIM são melhores que a Rede64 Lee. Logo, a melhoria de desempenho obtida com a Rede64 Sun é consistente e se mantém com a variação do diâmetro e da concentração das partículas.




Figura 42 – Probabilidade de sucesso de medição para diferentes de concentração de partículas (Rede64 Sun).




Figura 43 - RMSE e Erro Médio para diferentes concentrações de partículas (Rede64 Sun).

4.2.4

Considerações acerca da Rede64 Sun

A principal diferença entre a Rede64 Sun e a Rede 64 Lee se deve à inclusão dos resultados do estágio de processamento com correlação cruzada no treinamento da rede. Isso conferiu uma melhoria significativa nos resultados obtidos com a Rede64Sun. Os testes indicaram ainda que, em situações ideais, a Rede64 Sun apresentou resultados pouco melhores do que os métodos convencionais de interpolação *subpixel*. Os resultados obtidos nesta seção são promissores, dado que a estrutura em cascata da rede é bastante simples. Portanto, a partir desta seção serão analisadas estratégias para a medição do deslocamento

das partículas com precisão *subpixel*, baseadas no método da Rede64 Sun. A ideia é melhorar ainda mais o desempenho da rede na estimação dos deslocamentos com resolução *subpixel*, reduzindo assim a incerteza da técnica de PIV.

4.3

Modelo com três redes em paralelo (Rede64M1 Sun)

Os modelos até aqui utilizavam apenas cascatas de redes em série para a estimação dos deslocamentos. No entanto, o uso de mais redes neurais em paralelo reduz os erros aleatórios. Estratégias similares também são adotadas nos métodos de PIV tradicional (Hart, 1999). Nesta seção construiu-se uma rede com arquitetura composta por redes em paralelo e analisou-se o desempenho do método. Os testes são similares àqueles realizados nas seções anteriores, assim como as condições dos testes.

4.3.1

Arquitetura

A rede avaliada nesta seção foi construída com a técnica de *assembly network* para montagem de um módulo contendo três Redes64 Sun em paralelo. Este módulo corresponde ao segundo nível da cascata do PIV híbrido, onde o primeiro nível é o processo de correlação cruzada com *windows deformation*. A entrada das redes é composta por imagens deslocadas entre si, de acordo com os valores de deslocamento estimados pela correlação cruzada, do primeiro nível da cascata. A saída da Rede64M1 Sun é composta pela média aritmética simples da saída das três Redes64 Sun em paralelo. A Figura 44 demonstra a cascata com três redes em paralelo.

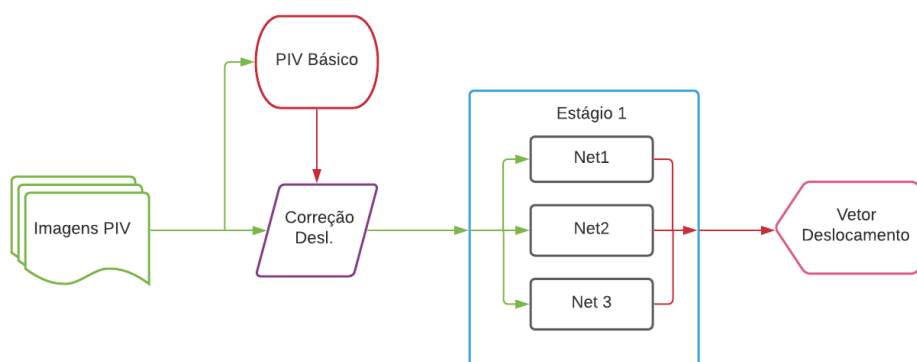


Figura 44 - Esquemático Rede64M1 Sun.

4.3.2

Dataset

O *dataset* de treinamento é o mesmo utilizado para a rede da seção anterior. Cabe ressaltar que utilizou-se um único *dataset* para treinar as três Redes. Logo, as redes foram treinadas seguindo a estratégia adotada na Rede64 Sun, onde os deslocamentos estimados pela correlação cruzada também são considerados no treinamento da rede.

4.3.3

Resultados dos testes de validação

Como já foi demonstrado que a Rede64 Sun é capaz de estimar o deslocamento das partículas, julga-se desnecessário incluir a imagem de deslocamento real versus deslocamento ideal. Assim, partiu-se diretamente para a análise do RMSE e do erro médio em relação ao deslocamento teórico. Na Figura 45, nota-se que os valores RMSE da Rede64M1 Sun são aproximadamente a metade dos valores do RMSE obtidos com a referência WIDIM. Os valores de erro médio também apresentam redução das oscilações no caso da Rede64M1 Sun e não mostram nenhuma tendência significativa.




Figura 45 - RMSE e Erro Médio (Rede64M1 Sun)

O histograma da Rede64M1 Sun, mostrado na Figura 46, apresenta uma mudança significativa em relação à referência. Nota-se um pico elevado e uma base estreita no caso da rede. Isso sugere uma redução considerável na incerteza das medições. Ainda assim, a Rede64M1 apresenta distribuição gaussiana de erro, indicando que os erros são de natureza aleatória e com distribuição normal.

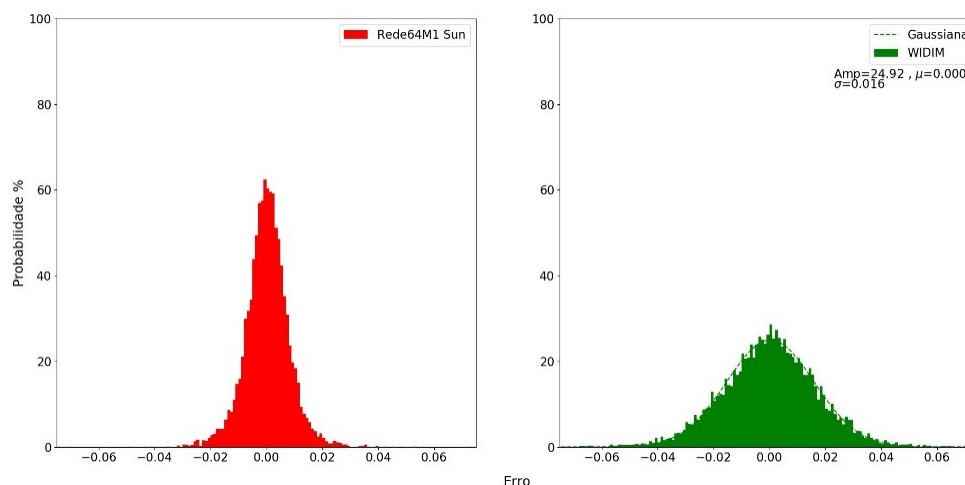


Figura 46 - Histograma do Erro (Rede64M1 Sun)

4.3.4

Teste de Robustez

Seguindo a mesma linha adotada nas seções anteriores, analisou-se também a influência do diâmetro e da concentração das partículas nos resultados da Rede64M1 Sun. A Figura 47 mostra a influência do diâmetro das partículas na probabilidade de sucesso na estimação do deslocamento das partículas. Nota-se que a probabilidade de sucesso em condições ideais atinge 100 % para partículas com diâmetros maiores do que, aproximadamente, 2,5 pixels. Nenhuma alteração significativa foi observada nesse caso com relação aos modelos anteriores.




Figura 47 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64M1 Sun)

Na Figura 48 é analisada a variação do erro médio e do RMSE com o diâmetro das partículas. Nota-se que os erros RMSE e médio se estabilizam para partículas com diâmetros maiores que 3 pixels, sendo que ambos se estabilizam próximo do mesmo valor. O erro médio

de ambos é bastante similar. No entanto, nota-se um aumento do erro da Rede64M1 nos casos com diâmetro das partículas próximos do limite utilizado no treinamento da rede. Na faixa entre 2,5 e 5 pixels os erros são da ordem de 1/1000 pixels.




Figura 48 - RMSE e Erro Médio por diâmetro de partícula (Rede64M1 Lee)

A probabilidade de sucesso nas medições com o método WIDIM atingem 100 % em concentrações um pouco menores do que aquelas observadas com a Rede64M1 (Figura 49). Isso sugere que o método tradicional é um pouco mais robusto do que a Rede64M1 Sun com relação a este parâmetro. Ainda assim, a Rede64M1 atinge probabilidades de sucesso próximas de 100 % para concentrações da ordem de 1 partícula por janela de interrogação, que é o mínimo possível para a técnica.




Figura 49 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64M1 Sun)

Os erros RMSE e médio são analisados na Figura 50 para uma faixa de concentrações onde a probabilidade de sucesso fica próxima de 100 %. Os resultados mostram claramente

que o erro RMSE da Rede64M1 Sun é em torno de 25 % menor do que o RMSE da referência para as diferentes concentrações testadas. Nessas condições, os erros médios dos dois métodos são centrados em zero e a REDE64M1 Sun apresenta oscilações um pouco menores em torno deste valor.




Figura 50 - RMSE e Erro Médio para diferentes concentrações de partículas (Rede64M1 Sun)

4.3.5

Considerações sobre a Rede64M1 Sun

A substituição da Rede64 Sun pelo módulo de três Rede64 Sun em paralelo provocou uma redução significativa do erro RMSE, de aproximadamente 25 %. Na maioria das condições testadas, o RMSE se manteve inferior ao método tradicional e consideravelmente menor do que o RMSE obtido com a rede testada inicialmente. A tendência na estimação dos dados continuou sendo muito próxima de zero, o que é muito importante. Com base nos resultados obtidos, buscou-se avaliar se seria possível reduzir ainda mais o erro da rede e consequentemente reduzir a incerteza na estimação dos deslocamentos. Conforme já mencionado em seções anteriores, não é claro qual o limite de resolução da técnica. Portanto, algumas arquiteturas mais complexas do que aquelas utilizadas até aqui serão avaliadas nas seções seguintes, com o intuito de se verificar se ainda há a possibilidade de redução dos erros aleatórios.

4.4

Modelo de Cascata híbrida com especialização por diâmetro de partícula (RedeD64M1 64M2 Sun)

Para melhorar ainda mais o desempenho do método com relação à resolução, decidiu-se otimizar as redes de acordo com o diâmetro das partículas. Para isso utilizou-se um esquema que é ilustrado na Figura 51. A estrutura do modelo consiste em um primeiro módulo composto pelo PIV convencional baseado em correlação cruzada, mas sem a interpolação *subpixel*. Em seguida, conectou-se uma rede especializada em medir o diâmetro da partícula (Rede Diam), por meio da qual selecionam-se quais módulos devem ser ativados nos estágios seguintes. Os dois módulos dos estágios seguintes, que são empregados para medição com resolução de *subpixel*, são treinados para trabalhar em uma faixa específica de diâmetros. Por isso, foi necessário estimar o diâmetro das partículas com a Rede Diam. Assim, buscou-se sempre trabalhar na menor faixa de incertezas da rede neural, buscando-se reduzir as incertezas das medições.

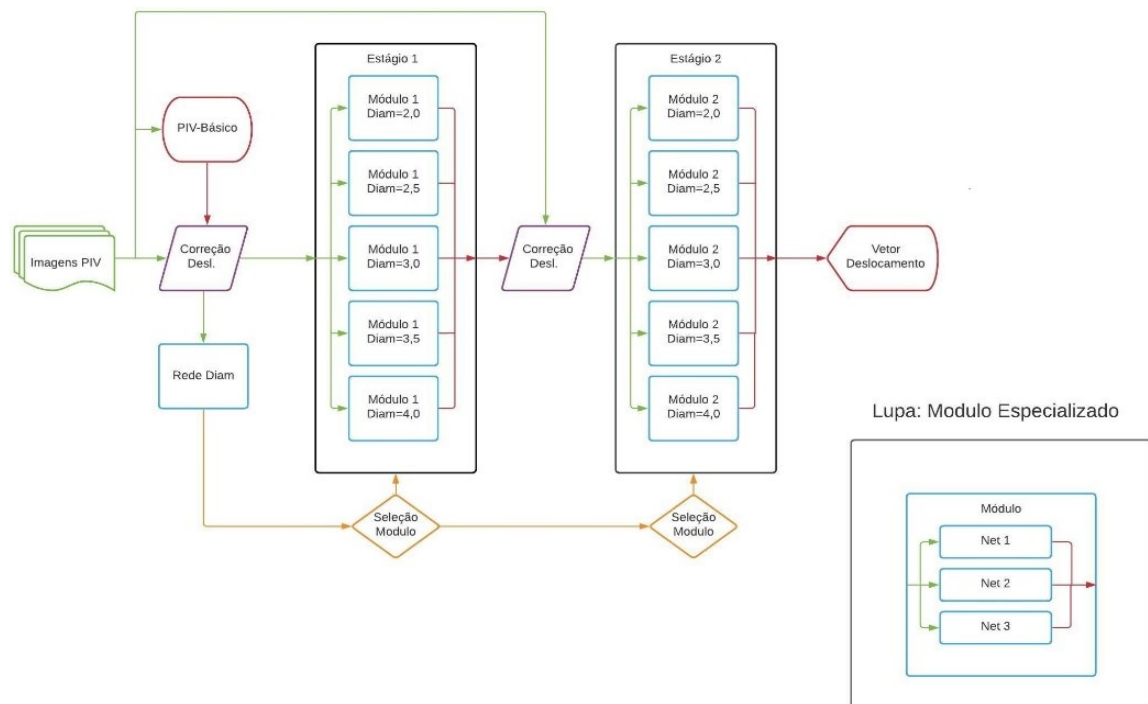


Figura 51 – Esquema RedeD64M1 – 64M2 Sun

4.4.1

Arquitetura para a Rede de medição de diâmetro (Rede Diam)

A Rede para medição de diâmetro é bastante similar à rede para medição de deslocamento, com entrada de duas janelas de 64x64 pixels e, ao invés de dois neurônios de saída para deslocamento em x e y, a rede possui apenas um para indicação do diâmetro. Na Figura 52 é mostrado um desenho esquemático da arquitetura desta rede. Os demais estágios são similares à Rede64M1 SUN.




Figura 52 – Arquitetura Rede Diam.

4.4.2

Dataset para a medição de diâmetro e treinamento

A rede de medição de diâmetro foi treinada para medição de diâmetros entre 1,5 pixels e 5 pixels, com concentração entre 0,01 ppp e 0,1 ppp. O dataset foi constituído por 500 mil pares de imagens e foi repetido 15 vezes com taxa de aprendizado de 10^{-4} e em seguida mais 2 vezes com taxa de 10^{-5} e finalmente mais 2 vezes com taxa de 10^{-6} .

4.4.3

Resultados da medição de diâmetro

Para avaliar o resultado da rede Diam foram realizados dois testes, sendo um para avaliar o funcionamento da rede para diferentes concentrações de partículas e outro para avaliar a capacidade do método na estimação do diâmetro médio das partículas das imagens de PIV.

A Figura 53 ilustra a probabilidade da rede estimar o diâmetro das partículas dentro de uma janela de interrogação com erro menor do que 0,05 pixel. Os dados são apresentados

para diferentes concentrações. Incluíram-se na figura os resultados obtidos com partículas de diferentes diâmetros. Nota-se que, para a estimação dos diâmetros com alguma confiabilidade, é necessária uma quantidade maior de partículas do que era necessário para se estimar o deslocamento dessas partículas. De certa forma, esse resultado tem algum sentido, pois apenas uma partícula, ou boa parte dela, precisa estar contida na imagem para que seja detectado algum deslocamento. Já a medição do diâmetro fica altamente comprometida pela falta de informações acerca das partículas. Logo, concentrações baixas e diâmetros muito pequenos dificultam a estimação do diâmetro das partículas com erro menor do que 0,05 pixel. Por isso, também se avaliaram neste teste casos com partículas de diferentes diâmetros.




Figura 53 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede Diam).

De acordo com os resultados da Figura 53, as estimações de diâmetro fornecidas pela rede atingem probabilidade de sucesso acima de 90 % para concentrações acima de 0,035 ppp e diâmetros maiores do que 2 pixels. Para concentração acima 0,035 ppp a rede parece se comportar de forma estável, com acerto de perto de 90 %. Logo, os demais testes realizados nesta seção consideram somente concentrações acima deste limiar.

Ainda com relação aos dados do teste de concentração de partículas, analisaram-se os valores do RMSE e do erro médio da medição do diâmetro (Figura 54). Observa-se que o erro médio se estabiliza para concentrações acima 0,02 ppp e o RMSE só se estabiliza para concentrações acima de 0,035 ppp. Nas concentrações em que o RMSE fica estável, o erro médio fica um pouco maior que zero, mas tanto o RMSE como o erro médio são menores do que 0,05 pixel, o que pode ser considerado satisfatório. Portanto, os resultados sugerem que

a Rede Diam funciona bem na faixa de diâmetros entre 2,5 e 4 pixels e concentrações acima de 0,035 ppp.




Figura 54 – RMSE e Erro Médio para diferentes concentrações de partículas (Rede Diam).

A Figura 55 ilustra a probabilidade da Rede Diam estimar o diâmetro das partículas com erro menor do que 0,05 pixel. Nesta figura, considerou-se a concentração constante e igual a 0,05 ppp. De maneira similar ao processamento do deslocamento das partículas, o erro aumenta muito no caso de partículas pequenas. Isso ocorre porque a informação em pixels adjacentes ao centro da partícula é perdida na digitalização. Nessas condições não é possível inferir qualquer informação com resolução sub-pixel. É interessante notar que a probabilidade de acerto sofre uma redução com o aumento do diâmetro das partículas. A princípio, isso pode parecer uma contradição, mas vale lembrar que a concentração é uma relação entre áreas. Logo, à medida que o diâmetro aumenta o número de partículas dentro da janela de correlação diminui, devido ao fato da concentração se manter constante.




Figura 55 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede Diam).

Os valores de erro RMSE e do erro médio na medição do diâmetro mostram que, apesar das dificuldades, é possível estimar os valores com razoável precisão na faixa de diâmetros entre 2 e 5 pixels. Nessa faixa o erro RMSE fica abaixo de 0,05 pixel e o erro médio abaixo de 0,01 pixel. Isso é mais do que suficiente para o arranjo proposto no esquema da Figura 52.




Figura 56 - RMSE e Erro Médio por diâmetro de partícula(Rede Diam)

4.4.4

Módulos Especializados

Na arquitetura proposta para estimação do deslocamento das partículas, consideraram-se dois módulos especializados. A especialização consiste no treinamento da rede para uma faixa específica de diâmetros das partículas. Assim, busca-se reduzir o erro nas estimações de deslocamento. Por isso, a detecção do diâmetro médio das partículas é importante, pois essa informação permite que seja selecionada uma rede treinada especificamente para

aquela faixa de diâmetros. Cada um dos módulos especializados é composto por três redes em paralelo, com entradas de $64 \times 64 \times 2$. As redes são iguais às empregadas nos módulos do modelo Rede64M1 Sun. A diferença principal ocorre no processo de treinamento.

Para treinar as redes dos módulos especializados foram selecionados os diâmetros de 2,0, 2,5, 3,0, 3,5 e 4,0 pixels, dada a eficiência da Rede Diam na identificação do diâmetro médio das partículas nesses intervalos. Para cada uma dessas faixas de diâmetros são treinados dois módulos especializados, de acordo com o método empregado na Rede64 Sun.

Para o primeiro módulo especializado foi usado um *dataset* contendo 1 milhão de pares de imagens, com deslocamento na faixa entre -10 a +10 pixels. Essas imagens passam pelo módulo de estimação de deslocamento com correlação cruzada e a posição das janelas é ajustada de acordo com os deslocamentos estimados pela correlação cruzada. Após esse procedimento, as imagens têm um deslocamento esperado na faixa de ± 1 pixel. Essas imagens são fornecidas para o treinamento da rede. O procedimento é o mesmo adotado no treinamento da Rede 64 Sun. A diferença é que a faixa de diâmetro das partículas era restrita de acordo com os intervalos pré-definidos para a especialização dos módulos. Para o treinamento do segundo módulo empregam-se os mesmos *datasets* utilizados anteriormente, com a diferença de que as imagens já haviam sido processadas pelo primeiro módulo especializado. Todo o procedimento segue a lógica do desenho esquemático da Figura 51.

4.4.5

Teste dos módulos especializados

Antes de realizar o teste completo da RedeD64M1 64M2 Sun, decidiu-se analisar a eficiência de cada módulo treinado para uma faixa específica de diâmetros das partículas. Os resultados de erro RMSE para cada estágio da rede são mostrados na Figura 57. Nos resultados do módulo 1, pode-se verificar que os menores erros aleatórios ocorrem na faixa entre 3 pixels e 4 pixels de diâmetro. Neste estágio, o RMSE das medições já atinge valores da ordem de $1/100$ pixel, que são ligeiramente menores do que aqueles obtidos com a técnica de PIV tradicional. Os resultados extraídos de (RAFFEL, WILLERT e KOMPENHANS, 1998) foram incluídos para dar uma ideia da redução do RMSE em relação à técnica tradicional. No segundo estágio, o valor RMSE é reduzido por uma ordem de grandeza e chega a valores da ordem de $1/1000$ pixel.




Figura 57 – RMSE dos módulos especializados de acordo com o diâmetro da partícula (Módulos especializados).

Nos dois gráficos da Figura 57, pode-se visualizar os pontos de interseção entre as curvas do RMSE de módulos da rede. Os pontos de interseção das curvas do primeiro e segundo módulo especializado foram usados como limiares para a seleção de quais módulos são usados no processamento. Os limites estabelecidos estão descritos na Tabela 2. Como o valor do diâmetro médio das partículas já havia sido estimado pela Rede Diam, essa seleção era simples de ser implementada.

Tabela 2: Limites de operação dos dois módulos

Diâmetro de treinamento	Faixa de operação do módulo do 1 estágio	Faixa de operação do módulo do 2 estágio
2,0	$X < 2,351$	$X < 2,235$
2,5	$2,351 < X < 2,779$	$2,235 < X < 2,830$
3,0	$2,779 < X < 3,344$	$2,830 < X < 3,197$
3,5	$3,344 < X < 3,832$	$3,197 < X < 3,773$
4,0	$3,832 < X$	$3,773 < X$

4.4.6

Teste de robustez

Na Figura 58 pode-se observar a probabilidade de acerto na estimação de deslocamento das partículas para diferentes concentrações. Como a Rede Diam só apresentou alguma probabilidade de acerto para concentrações acima de 0,01 ppp, nesta análise só foram consideradas concentrações acima deste valor. Observa-se que na faixa analisada o método tradicional já apresenta probabilidade de acerto próxima de 100 %. Naquele caso, a probabilidade de 100 % era obtida com valores de concentração da ordem de 0,05 pixel. No caso das redes especializadas, a mesma convergência só é observada com concentrações 4 vezes maiores. Esse já era um requisito esperado para o método proposto,

uma vez que a Rede Diam também só apresentou convergência para concentrações mais altas. De qualquer maneira, os valores de concentração requeridos não são muito altos e estão na faixa esperada de 6 a 10 partículas por janela de interrogação, que é a concentração empregada normalmente em medições PIV.

A Figura 59 apresenta os gráficos com o valor RMSE e do erro médio de acordo com a concentração de partículas. Pode ser visto em ambos os gráficos que a RedeD64M1-64M2 Sun é mais exata que WIDIM para todos os diâmetros testados. No entanto, isso só ocorre para concentrações acima de 0,02 ppp. A estabilização dos valores de erro médio e RMSE ocorre para concentrações acima de 0,035 ppp. Nesta faixa o valor RMSE é pelo menos uma ordem de grandeza inferior àquele obtido pela referência (WIDIM).




Figura 58 – Probabilidade de sucesso de medição para variação de concentração de partículas (RedeD64M1-64M2 Sun)




Figura 59 - RMSE e Erro Médio para diferentes concentrações de partículas (RedeD64M1-64M2 Sun)

Na Figura 60 pode ser visualizada a probabilidade de sucesso das medições com a variação do diâmetro das partículas. A RedeD64 M1 Sun e a RedeD64M1-64M2 Sun apresentam probabilidade de 100 % a partir do diâmetro de 2 pixels, enquanto a referência WIDIM só vai apresenta tais valores a partir de diâmetros de aproximadamente 2,5 pixels. Isso também era um comportamento esperado, uma vez que a rede é treinada especialmente para partículas em uma determinada faixa de diâmetros. Logo, sob o ponto de vista de diâmetro das partículas, a RedeD64 M1 Sun aparentemente tem capacidade de exibir melhor desempenho na presença de imagens com partículas pequenas.




Figura 60 - Probabilidade de sucesso de medição por diâmetro de partícula (RedeD64M1-64M2 Sun)

A análise do RMSE e do erro médio pode ser feita com base na Figura 61. Nesta análise mostram-se os resultados do primeiro estágio (RedeD64 M1) e do segundo estágio

(RedeD64M1 64M2), além da referência. De acordo com os gráficos, o valor RMSE da RedeD64M1 Sun é próximo ao valor encontrado pelo métodos de referência na faixa de diâmetros entre 3 e 4 pixels. Já o módulo 2 apresenta erros menores do que o WIDIM em toda a faixa de diâmetros analisada. Na faixa entre 2 e 4 pixels os valores de RMSE são uma ordem de grandeza menores do que aqueles obtidos pelo WIDIM. As ondulações que podem ser vistas no gráfico RMSE da RedeD6M1 M2 Sun ocorrem devido às mudanças na escolha da Rede especializada. O erro médio de todos os métodos fica próximo de zero, indicando que não há tendência significativa na estimativa dos deslocamentos.




Figura 61 - RMSE e Erro Médio por diâmetro de partícula (RedeD64M1-64M2 Sun)

4.4.7

Considerações acerca da RedeD64M1 64M2 Sun.

A Rede Diam foi utilizada com sucesso para medir o diâmetro médio das partículas. Os valores de erro na estimativa do diâmetro são baixos e permitem que os módulos especializados sejam bem escolhidos com base nos valores fornecidos pela Rede Diam. Uma desvantagem dessa rede é que ela necessita de concentrações mais altas de partículas para uma alta taxa de acerto das medições.

Os resultados obtidos com a RedeD64M1-64M2 Sun apresentam melhorias significativas quando comparados ao método tradicional (WIDIM) e às outras redes neurais testadas no âmbito desta dissertação. As incertezas das medições caíram de aproximadamente 1/50 pixel para aproximadamente 1/1000 pixel. A pergunta sobre qual o limite de resolução da técnica ainda não foi respondida, mas os resultados apresentados aqui mostraram que, em condições ideais, foi possível reduzir em uma ordem de grandeza a

incerteza nas estimativas de velocidade. As análises sugerem, ainda, que o uso de mais redes especializadas para resolver faixas mais restritas de diâmetros pode reduzir ainda mais as incertezas. O custo computacional neste caso pode se tornar um inconveniente, mas em princípio essa é uma possibilidade que pode ser explorada.

Um problema técnico observado é que o uso de muitos módulos especializados levou a um significativo aumento do tempo total de processamento, que passou a ser superior ao tempo de processamento do método de referência. No entanto, cabe ressaltar que não se buscou otimizar o processamento para reduzir o tempo computacional. O objetivo aqui foi demonstrar que as redes neurais podem ser combinadas com técnicas de PIV tradicional para obtenção de medições de velocidade com menor incerteza e consequentemente uma maior confiabilidade. Do ponto de vista metrológico, isso pode contribuir para que a técnica de velocimetria por imagem de partículas se torne padrão de medição de velocidade ou vazão em alguns casos específicos como, por exemplo, no caso de escoamentos bifásicos.

4.5

Modelo de Cascata híbrida de 3 níveis (Rede64M1-32M2 Sun)

Nas seções anteriores buscou-se reduzir a incerteza das medições, sem considerar a redução no tamanho das janelas de interrogação. Com isso, é de se esperar que, na presença de gradientes não constantes de velocidade, os erros devido a esse parâmetro se tornem muito altos e inviabilizem a medição com alta precisão. Conforme foi mencionado anteriormente, os efeitos dos gradientes de velocidade sobre as medições tendem a diminuir com a redução do tamanho das janelas. Em princípio, a redução do tamanho das janelas é uma tarefa mais simples e, portanto, neste trabalho deu-se mais enfoque à redução das incertezas. Apesar da implementação não ser complexa, a redução do tamanho das janelas implica em redução do número de partículas por janela e, portanto, constitui uma condição mais desafiadora para o processamento. De qualquer maneira, buscou-se nesta seção demonstrar como a redução no tamanho da janela pode causar uma diminuição dos erros associados à presença de gradientes.

4.5.1

Arquitetura

A arquitetura da rede empregada nesta seção, mostrada na Figura 62, será composta pelo WIDIM (sem interpolação subpixel), um módulo contendo redes 64M1 (janelas de 64 pixels no primeiro módulo da cascata) e um módulo de três redes 32M2 (janelas de 32 pixels no segundo módulo da cascata). A redução do tamanho da janela do primeiro módulo para o

segundo módulo foi feita com o intuito de reduzir os efeitos do gradiente de velocidade não linear nas medições. A saída do modelo é dada pela média das três redes do módulo 2. Cabe ressaltar que existem diversas formas de reduzir o tamanho da janela, e analisou-se aqui somente uma dessas possibilidades. Outra possibilidade seria alterar as redes testadas anteriormente para trabalhar com imagens de 32x32 pixels, mas este caso não será analisado neste trabalho.

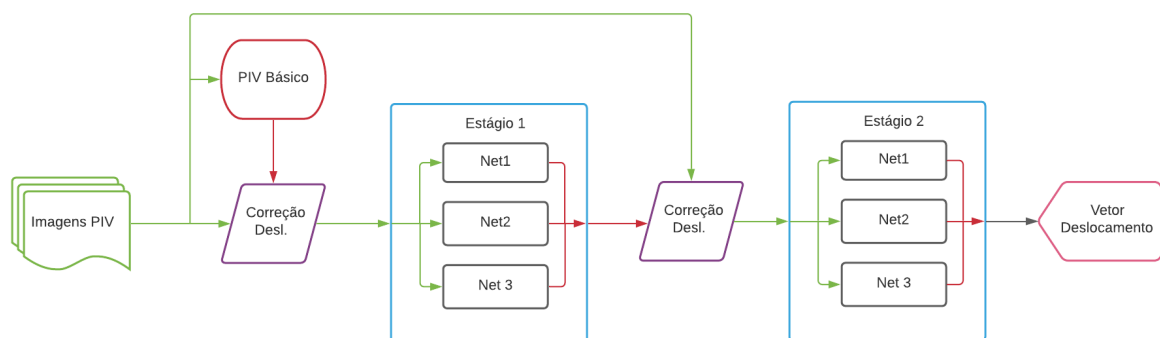


Figura 62 - Esquemático Rede64M1 Rede32M2 Sun.

4.5.2

Dataset

Todas as redes foram treinadas seguindo a mesma metodologia da Rede64 Sun, onde um *dataset* foi empregado para o treinamento de toda a rede e o resultado de um estágio anterior era empregado no treinamento do estágio seguinte.

4.5.3

Resultados dos testes de validação

Para verificar a estabilidade do método, traçaram-se os resultados de deslocamento obtidos pela rede em relação ao deslocamento teórico. A linha vermelha da Figura 63 corresponde ao caso da Rede proposta nesta seção (Rede64M1-32M2 Sun) e a curva em verde ao método WIDIM. Nota-se que ambos os casos apresentam alta aderência com os dados teóricos.




Figura 63 - Deslocamento mensurado x deslocamento real (Rede64M1-32M2 Sun)

Os valores do RMSE e do erro médio são mostrados na Figura 64. Observa-se que a Rede64M1-32M2 Sun exibe valores RMSE 75 % menores do que aqueles obtidos com o WIDIM. O aumento do erro em deslocamentos próximos de frações de 0,5 pixel ainda é observado nas medições com a rede. O erro médio continua centrado em zero, indicando que não há tendência significativa das medições.

O histograma dos erros mostrado na Figura 65 mostra que a distribuição é centrada em zero e tem elevada curtose, indicando uma baixa dispersão dos dados. Novamente, isso mostra uma redução significativa na incerteza das medições. Além disso, a distribuição não apresenta concentração de deslocamentos em valores específicos de erro, mantendo uma boa aderência à distribuição gaussiana. Logo, os erros aparentemente continuam sendo de natureza aleatória e com distribuição normal.




Figura 64 - RMSE e Erro Médio (Rede64M1-32M2 Sun).




Figura 65 - Histograma do Erro (Rede64M1-32M2 Sun)

4.5.4

Resultados do Teste de Robustez

A probabilidade de sucesso da rede com a variação do diâmetro pode ser analisada a partir da Figura 66. Na figura, observa-se que a Rede apresenta desempenho levemente melhor ao método WIDIM. Ainda assim, a melhoria é marginal e pode-se dizer que os dois métodos têm probabilidade de sucesso próxima de 100 % para uma faixa de diâmetros equivalente. Essa consideração é válida somente para a faixa analisada, podendo não ser válida para partículas com diâmetro maior do que 6 pixels.




Figura 66 - Probabilidade de sucesso de medição por diâmetro de partícula (Rede64M1-32M2 Sun)

De acordo com a Figura 67, o RMSE obtido pela Rede64M1-32M2 Sun é menor do que aquele obtido com o WIDIM para toda a faixa de diâmetros. Já os erros médios apresentam comportamento semelhante nos dois métodos. Além disso, o valor fica centrado em zero, indicando que nenhuma tendência significativa é observada nas estimativas de deslocamento.




Figura 67 - RMSE e Erro Médio por diâmetro de partícula (Rede64M1-32M2 Sun)

As probabilidades de sucesso das medidas com a Rede64M1-32M2 Sun e com WIDIM são similares quando se considera a concentração de partículas, conforme ilustrado na Figura 68. Lembrando que para estes testes fixou-se o diâmetro das partículas em 3 pixels. Nos dois casos, a probabilidade chega em patamares próximos de 100 % para concentrações acima de aproximadamente 0,005 ppp.




Figura 68 - Probabilidade de sucesso de medição para variação de concentração de partículas (Rede64M1-32M2 Sun)

A análise da variação dos erros com a concentração das partículas Figura 69 indica que o valor RMSE da Rede64M1-32M2 Sun nas condições do teste é aproximadamente um terço do valor obtido com o WIDIM. Isso é observado para a maior parte da faixa de concentração de partículas analisada neste trabalho. Logo, os resultados sugerem que a incerteza da rede tende a ser menor do que a do método de referência. Seguindo os resultados dos testes anteriores, não se observa no erro médio nenhuma tendência significativa na estimação dos deslocamentos.





Figura 69 - RMSE e Erro Médio para diferentes concentrações de partículas (Rede64M1-32M2 Sun)

4.6

Resultado: Análise de um jato laminar

Com a redução do tamanho da janela de interrogação, espera-se que os efeitos de gradientes não uniformes de velocidade sejam reduzidos. Para avaliar o desempenho da Rede64M1 32M2, decidiu-se revisitar o problema do jato laminar. Assim, buscou-se verificar o comportamento do campo de velocidades e compararam-se os resultados com a referência WIDIM. Os resultados são mostrados na Figura 70. Para facilitar a comparação dos resultados obtidos nesta seção com aqueles relatados para a Rede64 Lee (com janela de 64pixels), reproduziu-se novamente a Figura 29. No caso da Rede64M1 32M2, nota-se uma redução considerável da diferença entre os resultados obtidos com Rede e com o método convencional. Na saída do bocal ainda existem diferenças significativas, mas nessas regiões os gradientes são elevados e para reduzir a diferença tanto o método WIDIM como a Rede precisariam de uma janela de interrogação ainda menor.

De qualquer maneira, este teste simples serve para ilustrar que uma redução dos erros associados ao gradiente de velocidade requer uma diminuição do tamanho das janelas. Em princípio isso é importante em casos onde os gradientes são não uniformes e possuem variação significativa em comprimentos da ordem do tamanho da janela. Em casos nos quais estes efeitos são desprezíveis, espera-se que os erros associados aos métodos de interpolação *sub-pixel* sejam dominantes.



(a)




Figura 70 – (a) Jato Laminar (Rede 64 Lee) ,(b) Jato Laminar (Rede64M1-32M2 Sun).

4.7

Considerações sobre a Rede64M1-32M2

A Rede64M1-32M2 Sun apresentou bons resultados nos testes de robustez, possuindo valores RMSE bem abaixo dos valores encontrados pelo WIDIM. Além disso, o erro médio apresenta-se centrado em zero e com menores oscilações que o WIDIM.

O teste do jato laminar demonstrou que a redução no tamanho da janela de interrogação foi capaz de reduzir consideravelmente a diferença em relação ao método de PIV tradicional. Isso era esperado, de acordo com as análises feitas no âmbito deste trabalho. Sabendo que erros associados a gradientes não uniformes tendem a se tornar menores com a redução do tamanho das janelas, julga-se que a implementação dos métodos aqui propostos deva seguir a tendência de redução do tamanho das janelas de interrogação. Em princípio essa tarefa não constitui um grande desafio do ponto de vista do método, mas é desafiadora do ponto de vista de condições de medição. Esta etapa foge do escopo deste trabalho. Julga-se que os resultados apresentados até aqui contribuam para o desenvolvimento de novas estratégias de processamento de imagens de PIV, com alta resolução espacial e baixa incerteza.

5 Conclusões

Durante esse trabalho foi realizada uma análise do trabalho de (LEE; YANG; YIN, 2017) e constatadas possibilidades de melhoria do método de PIV baseado em redes neurais convolutivas. Dentre os problemas encontrados, o fato da rede encontrar dificuldade em processar imagens com elevados gradientes de deslocamento, fato que também ocorreu em (RABAULT; KOLAAS; JENSEN, 2017), se mostrou de difícil resolução pois necessitaria de um *dataset* maior e mais complexo, o que acarretaria uma rede ainda mais complexa e maior tempo computacional para treinamento. Assim decidiu-se adotar a limitação de trabalhar-se com escoamentos uniformes. Isso reduz bastante o uso da rede, mas em compensação proporciona ganhos na qualidade da medição para este tipo de escoamento. Outro problema encontrado foi o da limitação de máximo deslocamento em que a cascata de rede proposta no artigo de Lee podia realizar devido ao tamanho das janelas usadas no trabalho e ao dataset de treinamento. Para resolver esse problema foi adotada a solução de usar a correlação cruzada, junto com o método de *windows deformation*, já amplamente usados na literatura, para fazer o cálculo de deslocamento no nível de pixel, enquanto seriam usadas as redes neurais convolucionais para a estimativa do deslocamento subpixel.

Os testes realizados com a Rede64 Lee demonstram que é possível utilizar a correlação cruzada como primeiro nível da cascata e assim trabalhar com deslocamentos maiores. Além disso, diversas técnicas de otimização já foram desenvolvidas para eliminar *outliers* e melhorar as medições no nível de pixel que poderão continuar sendo usadas. O cálculo da correlação cruzada simples é mais rápido que o uso da rede nos primeiros estágios, além de já ter sido amplamente utilizado na literatura. Desta forma, também se ganha em tempo de processamento, apesar de não ser intenção deste trabalho analisar o custo computacional e o tempo de processamento. Outro aspecto é que a adoção dos métodos baseados em redes neurais se torna suplementar ao já estabelecido, o que ajuda na aceitação do método por parte da comunidade e aproveita os desenvolvimentos dos métodos clássicos feitos até então.

Em (LEE; YANG; YIN, 2017) os autores definiram a arquitetura da sua rede com base no trabalho de (SUN; WANG; TANG, 2013), que tratava de deslocamento de objetos. No entanto, para treinar a rede, estabeleceram um *dataset* de treinamento para cada rede, e cada rede seria treinada separadamente, enquanto que em (SUN; WANG; TANG, 2013) as redes

foram treinadas utilizando resultados do nível anterior. A princípio o que se descobriu é que, quando se treina com imagens com gradiente elevados, ocorre a presença de *outliers* no cálculo de um nível da cascata, os quais dificultam o treinamento das redes no nível seguinte, que ficam focadas em reduzir o erro dos *outliers* (principal fonte de erro) ao invés de melhorar as medições corretas do nível anterior. Como foi dado foco na medição sem elevados gradientes, o método de treinamento em (SUN; WANG; TANG, 2013) se mostrou mais efetivo, como demonstrado nos resultados da Rede64 Sun, se comparados aos da Rede64 Lee.

O processo de aumentar o nível de cascata consiste em um processo de refinamento de resultados, o que no entanto traz dois problemas: (i) para treinar a rede seguinte pelo modelo de Sun, deve-se evitar que o resultado do nível anterior tenha uma alta distribuição de erro, conforme já mencionado; (ii) o processo de interpolação subpixel para o deslocamento de imagens de um nível para outro tem um alto custo computacional, além de ser uma fonte de erro. Assim deve-se procurar reduzir a aleatoriedade do erro ao máximo possível antes passar para o nível seguinte.

A maneira mais fácil de reduzir a aleatoriedade do erro é realizar mais medições e obter a média dessas medições. Assim, foi feito um modulo de três redes na camada, para reduzir o erro aleatório. A Rede64M1 Sun, composta por estas três redes, apresentou boa redução do erro aleatório, como demonstrado nos gráficos RMSE (erro aleatório de medição da rede), e nas oscilações do erro médio (erro aleatório do treinamento da rede, mas sistêmico para a rede já treinada).

As imagens do jato parecem apresentar o efeito de *smoothing*, ou seja, fazem uma análise média da velocidade dentro da janela. Para reduzir esse efeito, na técnica de PIV convencional se aplica o processo de redução do tamanho de janelas. Assim decidiu-se elaborar um terceiro nível da cascata composto por uma “janela” de 32x32. A criação do terceiro nível, com um modulo de três redes em paralelo, criando a cascata Rede64M1-32M2 Sun, provocou uma redução acentuada do erro, fazendo com que o RMSE caísse a um terço do valor do WIDIM e o erro médio apresentasse oscilações bem menores. A Rede64M1-32M2 Sun apresenta resultados comparáveis aos do estado da arte com interpolação subpixel Gaussiana. A imagem do jato laminar ainda continua apresentando o efeito *smoothing*, no entanto apresenta uma mudança menos gradual da coloração, mostrando que houve redução do efeito da Rede64M1-32M2 Sun.

O desenvolvimento da RedeD64M1-64M2 Sun reduziu em uma ordem de grandeza o valor RMSE se comparado ao WIDIM. O treinamento para a concentração específica de 0,05 ppp não provocou perda considerável em medições perto desta concentração. A utilização de módulos treinados para diâmetros específicos provocou oscilações na qualidade

da medição, e assim se sugere o uso de uma faixa estreita que se sobrepõe ao invés de diâmetros específicos, que se mostram de difícil utilização na prática.

5.1

Sugestões para trabalhos futuros

A primeira sugestão é que, para o processo de deslocamento de janelas entre um nível e outro da rede neural, a primeira janela deve ser mantida constante, fixa na posição, enquanto a segunda janela deve ser movimentada no sentido oposto ao deslocamento calculado no nível anterior. Isto seria feito em contraste com o que foi usado em (LEE; YANG; YIN, 2017), onde metade do deslocamento é feito pela primeira janela no sentido do deslocamento e metade pela segunda janela no sentido oposto ao do deslocamento. No treinamento de Lee essa característica fazia com que a medição real realizada estivesse sempre localizada a alguns pixels do local que se queria medir. Já no treinamento de Sun, o fato do treinamento ser dependente reduz em parte esse erro, mas provoca a redução da área similar entre as janelas.

A segunda sugestão é utilizar a abordagem de treinamento de (SUN; WANG; TANG, 2013), mas utilizar um dataset de treinamento diferente para cada rede. Ao se utilizar o mesmo dataset para todas as redes, padronizam-se as redes a determinados padrões de janelas, e assim se transformam fatores aleatórios, incluindo erro de geração, em fatores sistemáticos. Os erros aleatórios seriam parcialmente tratados com a média feita em cada modulo da cascata.

A terceira sugestão é utilizar o processo de *window deformation* entre os níveis da cascata. Esse processo reduziria drasticamente os gradientes entre o par de imagens, possibilitando o aumento da sensibilidade da medição também para o caso geral e não apenas para o caso de escoamento uniforme.

A quarta sugestão consiste em utilizar uma rede não supervisionada para separar as janelas em padrões, e utilizar uma cascata para cada padrão, o que deve melhorar a precisão do modelo de forma geral.

A quinta sugestão é o uso *generative adversarial network* (GAN) para reduzir o ruído e aumentar a resolução das imagens PIV. O processo de aumentar a resolução aumentaria a informação por partículas (a interpolação insere informação baseada no dataset de imagens usadas para treinar a rede), reduziria o *overlap* de informação devido à concentração e reduziria o gradiente das janelas.

6 Referências Bibliográficas

BISHOP, J. M. History and philosophy of neural networks. **Computational Intelligence**, v. 1, p. 400, February 2015.

BRENNEN, C. E. **Fundamentals of Multiphase Flow**. California : Cambridge University Press 2008, 2008.

BRYSON, A. E. A gradient method for optimizing multi-stage allocation processes. In **Proceedings of the Harvard Univ. Symposium on digital computers and their applications.**, 1961.

CHOLLET, F. **Deep learning with Python**. New York: Manning Publications., 2017.

CORREIA, C. E. R.; DE PAULA, I. B.; AYALA, H. V. H. ROBUSTNESS ASSESSMENT OF CASCADED DEEP CONVOLUTIONAL NEURAL NETWORKS FOR PARTICLE IMAGE VELOCIMETRY. **ABCM.COBEM2019**, n. COB2019, 2019.

DE PAULA, I. B. **Medidas Pontuais de Velocidade**. Rio de Janeiro, p. 1-55. 2015.

DESHPANDE, A. **A Beginner's Guide To Understanding Convolutional Neural Networks.**, 2017. Disponível em: <<https://adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/>>. Acesso em: 23 junho 2020.

DRAZIN, P. G. **Introduction to Hydrodynamic Stability**. Cambridge: Cambridge University Press, 2002.

FABRO, J. A. Curso de Especialização em Inteligência Computacional. **Redes neurais artificiais**, 2001. Disponível em: <<http://www.dainf.ct.utfpr.edu.br/~fabro/IF67D/redesneuraisartificiais.pdf>>. Acesso em: 05 maio 2020.

FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, v. 36, n. 4, p. 193–202, 1980.

GÉRON, A. **Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. Segunda. ed. Sebastopol: O'Reilly Media, 2017.

GLOROT, X.; BORDES, A.; BENGIO, Y. Deep Sparse Rectifier Neural Networks. **Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics**, 2011.

GRANT, I. et al. Neural-network method applied to the stereo image correspondence problem in three-component particle image velocimetry, v. 37, n. 17, p. 3656-3663, 1998.

GRANT, I.; PAN, X. An investigation of the performance of multi layer, neural networks applied to the analysis of PIV images. **Experiments in Fluids**, 1995.

GRANT, I.; PAN, X. The use of neural techniques in PIV and PTV. **Measurement Science and Technology**, 1997.

HEBB, D. O. **The organization of behavior**: a neuropsychological theory. New York: John Wiley and Sons, Inc., 1949.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **PNAS**, 1982.

KOHONEN, T. Self-organized formation of topologically correct feature maps. **Biological Cybernetics**, v. 43, p. 59-69, 1982.

LECUN, Y. E. A. Backpropagation applied to digit recognition Neural computation , 1989. Disponível em: <<https://www.ics.uci.edu/~welling/teaching/273ASpring09/lecun-89e.pdf>>.

LECUN, Y. E. A. Gradient-Based learning applied a document recognition.. **proc. OF THE IEEE**, 1998.

LEE, Y.; YANG, H.; YIN, Z. PIV-DCNN: cascaded deep convolutional neural networks for particle image velocimetry. **Experiments in Fluids**, v. 58, n. 12, p. 1-10, 2017.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier Nonlinearities Improve Neural Network Acoustic Models. **Proc. icml**, 2013.

MANDHANE, J. M.; GREGORY, G. A.; AZIZ, K. A flow pattern map for gas-liquid flow in horizontal pipes. **Int. Journal of Multiphase Flow**, 1, 1974. p537-553.

MCCLELLAND, J.; RUMELHART, D. E. **Parallel Distributed Processing**: exploration in the microstruture of cognition. Cambridge: MIT PRESS, 1987.

MCCULLOCH, W. S.; PITTS, W. A logical calculus nervous activity. **Bulletin of Mathematical Biology**, v. 52, n. 1, p. 99-115, 1943.

MENDONÇA, M. T. **Laminar Flow Stability**: Linear Theory. II Escola Brasileira de Primavera Transicao e Turbulencia - ETT 2000. Uberlandia: ABCM. 2000. p. 98-117.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**. Cambridge: MIT PRESS, 1969.

NEVES, G. Z. D. F.; GALLARDO, N. P.; VECCHIA, F. A. D. S. **Climate**, v. 5, p. 1-17, 2017.

PAULA, I. B. D.; ABRANTES, J. K.; AZEVEDO, L. F. A. MEDIÇÃO DE ESCOAMENTOS TURBULENTOS UTILIZANDO VELOCIMETRIA POR IMAGEM DE PARTÍCULAS. **Turbulência**, Rio de Janeiro, v. 8, n. 1, p. 133-209, 2012.

RABAULT, J.; KOLAAS, J.; JENSEN, A. Performing particle image velocimetry using artificial neural networks: A proof-of-concept. **Measurement Science and Technology**, 2017.

RAFFEL, M.; WILLERT, C. E.; KOMPENHANS, J. **Particle Image Velocimetry: A Pratical Guide**. 3ª. ed. Berlin: Springer, 1998.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.

SCARANO, F. Iterative image deformation methods in PIV. **Measurement Science and Technology**, 2002.

SIDHU, R. Layman's Introduction to Backpropagation.. **towardsdatascience**, 2019. Disponível em: <<https://towardsdatascience.com/laymans-introduction-to-backpropagation-efa2c64437db>>. Acesso em: junho 2019.

SUN, Y.; WANG, X.; TANG, X. Deep convolutional network cascade for facial point detection.. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, p. 3476–3483, 2013.

TAITEL, Y.; DUKLER, A. E. A model for predicting flow regime transitions in horizontal and near horizontal gas-liquid flow. **AIChE Journal**, 22, p. p47-55, 1976.

TARASHIMA, S. E. A. GPU accelerated direct cross-correlation PIV with window deformation. **15th Int Symp on Applications of Laser Techniques to Fluid Mechanics**, Lisboa, 2010.

WERBOS, P. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences**. Cambridge: Appl. Math. Harvard University, 1974.

WIDROW, B. Adaptive sampled-data systems. **IFAC Proceedings Volumes**, 1960.