

Analysis of the calibration of magnetic resonance equipment through the application of Deep Learning on phantom images

Abstract—Since the first magnetic resonance imaging (MRI) equipment created in 1974, experts have been studying how to continuously improve its image quality. This quality might depend on several technical and clinical factors, but before improving any factor to enhance the MR image quality, it is necessary to make sure that the corresponding equipment or system is perfectly calibrated. Until today, the technical procedure used in practice for checking the quality of MRI calibration is based on the standardized mathematical relationship between the signal and noise of the texture of parts of the phantom image, known as signal-to-noise ratio (SNR). This work proposes and implements the use of Deep Learning (DL), more specifically the DL method called Few-Shot Learning, to automatically classify entire phantom images that have been analysed by experts to check calibration during and daily after installation of an MRI system. The well-known Daily Quality Assurance protocol was applied here to acquire these images. A total of 53 phantom images were acquired on calibrated and non-calibrated scenarios carried out by a technical expert. Our experimental results show an automatic promising classification accuracy (calibrated vs. non-calibrated) of 97.0% +/- 4.50%, discriminating not only the texture differences commonly captured by SNR, but also other noisy effects like distinct geometry and spatial position of the phantom related to the analysis of its whole image.

I. INTRODUÇÃO

Desde a criação do primeiro equipamento de ressonância magnética (RM), em 1974, especialistas vêm estudando a melhoria contínua da qualidade das imagens [McRobbie et al. 2006].

Esta qualidade depende de vários fatores, mas antes de calibrar/ajustar qualquer fator para a melhoria da imagem, é necessário certificar de que o equipamento de RM esteja perfeitamente calibrado.

A qualidade da imagem é medida principalmente pela relação entre o sinal emitido e a quantidade de ruído obtido durante a aquisição da imagem, chamada de *Signal Noise relation* - SNR.

Os primeiros trabalhos de cálculo da SNR foram publicados na década de 1970 [McRobbie et al. 2006], mas foi a partir de 1990, que trabalhos mais predominantes começaram a ser publicados por [Marcovski 1996]; [Constantinides et al. 1997]; [Goerner and Clarke 2011]; [Guerin et al. 2017].

O trabalho realizado por [Andrioli and Thomaz 2021] utilizou análise multivariada de dados de alta dimensão [Giraldi et al. 2008]; [Sato et al. 2009]; [Fisher 1936]; [Koriwakova et al. 2010]; [Pang and Mak 2015]; [Janousova et al. 2015]; [Sharma 2017] e [Hastie et al. 2009], Análise de Componentes Principais (Principal Component Analysis, PCA) [Sato et al. 2009]; [Koriwakova et al. 2010]; [Pang and Mak 2015] + Análise Discriminante Linear Máxima (Maximum Linear Discriminant Analysis, MLDA) [Thomaz and Gillies 2006]; [Andrioli and Thomaz 2021], como alternativa ao SNR.

O Aprendizado Profundo *Deep Learning* - DL esta sendo usado com sucesso para alcançar o estado da arte em uma variedade de aplicações, como pesquisa na web, detecção de spam, geração de legendas e fala e reconhecimento de imagem. No entanto, esses algoritmos geralmente não correspondem adequadamente quando são colocados a fazer previsões sobre dados em que pouca informação supervisionada está disponível. Nós desejamos trabalhar com essas categorias desconhecidas sem necessitar de extensa reciclagem, que pode ser cara ou impossível, devido a dados limitados [Koch 2015].

De acordo com [Lake et al. 2011], os seres humanos exibem uma forte capacidade de adquirir e reconhecer novos padrões. Em particular, observamos que quando apresentados com estímulos, as pessoas parecem ser capazes de compreender novos conceitos rapidamente e então reconhecer as variações desses conceitos em percepções futuras.

Uma tarefa particularmente interessante é a classificação do que podemos observar, com apenas um único exemplo de cada classe possível, antes de fazer uma previsão sobre um teste. Este processo é chamado de aprendizado único ou de poucas amostras (*Few Shot Learning* - FSL) [Fei-Fei et al. 2006] e [Lake et al. 2011].

Realizamos a análise de imagens de ressonância magnética, especialmente das imagens de *Phantom* com ruídos através de inteligência artificial, utilizando um aprendizado de poucas amostras (FSL) composto de uma rede neural convolucional (*Convolutional Neural Network* - CNN), como extrator de características. A CNN utilizada foi a *Visual Geometry Group* de onze camadas internas (VGG11).

As principais contribuições deste trabalho são as seguintes:

- 1) Propomos uma Rede Siamesa interpretável para gerar respostas de alta qualidade para análise com poucos disparos em relação a uma ação e um objeto de entrada, e desta forma diminuir o problema do uso de poucos dados.
- 2) Experimentos empíricos conduzidos em dois conjuntos de dados do mundo real que mostram a eficácia do nosso modelo proposto, na tarefa de detecção de poucas amostras.

II. CONCEITOS FUNDAMENTAIS

Em 1997, [Constantinides et al. 1997] realizou um estudo para comparar a resposta do *SNR* de acordo com as bobinas de 2 e de 4 canais, utilizando uma ressonância de 1,5 Tesla de corpo inteiro. Como objeto de pesquisa foi utilizado um phantom cilíndrico de água (como usado neste trabalho) colocado no centro espacial de cada bobina, de forma a obter a melhor imagem do phantom e menor ruído como resultado. Observou-se que, a bobina de 4 canais apresentou um *SNR*, aproximadamente, 20% melhor do que a bobina de 2 canais. Em razão disso, a maioria dos equipamentos atuais de RM trabalham com bobinas de *phased array* para exames de longa amplitude, como exames de coluna e abdômen.

Com o avanço da tecnologia, foram criadas novas bobinas de recepção de imagem denominadas de *phased array*.

Em 2000, [Kuperman 2000], utilizando as bobinas de *phased array*, demonstrou que os três mais importantes parâmetros que definem a qualidade espacial da imagem são a resolução espacial, o contraste da imagem e o *SNR*. Constatou que o único fator que não pode ser reprocessado, e que depende individualmente de cada local que a ressonância está instalada, se refere aos fatores físicos, externos ao equipamento e que influenciam diretamente na imagem, gerando ruído. Estudou o *SNR* para imagens tridimensionais (3D) e fez o comparativo entre o *SNR* bidimensional (2D) com o tridimensional (3D) e verificou que o *SNR* 3D é sempre menor que o 2D.

[Schnell et al. 2000] concluiu em seu estudo que bobinas comuns apresentam melhor *SNR* entre 30 a 40MHz; as bobinas chamadas *loop* apresentam uma melhor resposta de *SNR* para frequências de 50MHz e as bobinas *birdcage* para frequências de até 70MHz. Para campos magnéticos de maior intensidade, as frequências de trabalho são maiores também. Assim para uma ressonância de 1,5T a frequência de trabalho é de 63MHz de acordo com a Lei de Larmor [McRobbie et al. 2006].

Em 2001, [Vaughan et al. 2001] apresentou uma comparação entre ressonâncias de 4T e de 7T em exames de crânio e a constatação foi de que, comparado com a ressonância de 4T, a ressonância de 7T apresentava um *SNR* 1,6 vezes maior.

De acordo com [Dietrich et al. 2007], vários métodos para se calcular a *SNR* foram descritos anteriormente, mas o mais importante é o método que calcula estatisticamente duas regiões distintas das imagens, sendo uma fora da área de análise (fundo) para se medir o ruído e outra da região da

área analisada para se medir a intensidade do sinal. Avaliou o uso das duas regiões, descritas no artigo anterior, nas técnicas alternativas de bobinas de superfície (*phased array*) e no paralelismo de imagens, e também apresentou nova técnica de cálculo da *SNR* baseado na diferença de duas imagens repetidas (idênticas) através de 60 imagens em phantom, das mais diversas formas.

Em 2016, pela sua tese [Liu 2016], forneceu uma explicação do que pode gerar ruído na aquisição da imagem de ressonância magnética. Entre as fontes de ruído, ele apresentou o ruído de fundo, o ruído de movimento, o ruído de fluxo sanguíneo e o ruído de desvios e flutuações de baixa frequência.

Neste artigo, a linha entre sinal e ruído nem sempre é clara. O desafio na distinção entre sinal e ruído decorre do fato de que o cérebro, que é o objeto de estudo, é o gerador de sinais de interesse e ruído.

Portanto, minimizar as contribuições dessas fontes de ruído, arrisca a remoção de informações sobre a atividade cerebral subjacente. Como a RM continua a evoluir, será importante que pesquisadores permaneçam atento a esse problema e desenvolvam novas abordagens de análise que considerem mais efetivamente a interação entre sinal e ruído.

III. TRABALHOS RELACIONADOS

Em 2021, [Andrioli and Thomaz 2021] realizaram a comparação entre *SNR* e a utilização de análise estatística (*PCA + MLDA*) na análise de imagens de *Phantom* em ressonância magnética. Concluíram que o processo estatístico que analisa a imagem por completo (considerando sua geometria, posicionamento, ruído e artefatos (acontecimentos que fazem a imagem não ser ideal)) é mais criterioso que o processo da *SNR* que realiza apenas um cálculo entre a área pertencente à imagem (dentro do *Phantom*) e a área externa ao *Phantom* que representa o ruído.

Em 2022, [Wang et al. 2022] apresenta um incremento do *SNR* para imagens patológicas cerebrais usando processo espiral e protocolo T1, concluindo que este processo aumenta a *SNR*.

Com referência ao processo de *Deep Learning* proposto neste trabalho, em 2010, [Dahia and Segundo 2020] apresentaram um trabalho denominado *Meta Learning for Few - Shot One - class Classification* propondo um método para realizar a classificação de uma amostra à partir de um pequeno número de exemplos. Formularam o aprendizado de recursos significativos para a classificação de uma classe, como um problema de meta-aprendizagem para aprender um recurso de representação. Para aprender essas representações, utilizaram dados multi-classe de tarefas semelhantes. Mostraram como o método de suporte de descrição de dados vetoriais pode ser usado, e também propuseram uma variante mais simples baseada em Proto-Redes. Validaram a abordagem adaptando e agregando conjuntos de dados de classificação de poucos tiros para os conjuntos de dados de poucos tiros, usado como cenário de classificação de classe, obtendo resultados semelhantes ao estado da arte da classificação tradicional de

uma classe, e que melhorou as linhas de base de classificação de uma classe empregado na configuração de poucos tiros.

Em 2021, [Xia et al. 2021] propuseram a intenção de detecção de poucos disparos como uma tarefa desafiadora devido ao problema de anotação de susto. Propuseram uma Rede Pseudo-Siamesa (*PSN*) para gerar dados rotulados para intenções de poucos disparos e aliviar esse problema. A *PSN* consiste em duas sub-redes idênticas com a mesma estrutura, mas com pesos diferentes: uma rede de ação e uma rede de objetos. Cada sub-rede é um *autoencoder* variacional baseado em transformador que tenta modelar a distribuição latente de diferentes componentes na sentença. A rede de ação é aprendida a entender os pesos de ação e a rede de objetos se concentra em expressões relacionadas a objetos. Ele fornece uma estrutura interpretável para gerar um enunciado com uma ação e um objeto existente em uma determinada intenção. Experimentos em dois conjuntos de dados do mundo real mostraram que a *PSN* alcança desempenho de última geração para a tarefa generalizada de detecção de poucos disparos.

IV. FUNDAMENTOS TEÓRICOS

A principal inspiração para as ideias do nosso artigo veio do campo da meta-aprendizagem, em particular, a de realizar a classificação através de poucas amostras pois durante a calibração do equipamento de RM são realizadas poucas imagens em comparação durante ao seu funcionamento normal na realização de exames de pacientes, onde são realizadas no mínimo 120 à 150 imagens por exame. De acordo com [Snell et al. 2017], Redes Prototípicas são classificadores de poucas amostras que criam protótipos através de alguns exemplos rotulados. Redes Prototípicas de uma classe são a variante de uma classe deste método. [Lee et al. 2019] propôs aprender representações características para rede de classificação convexa de poucas amostras incluindo Máquinas de Vetor de Suporte multi-classe [Cortes and Vapnik 2004], com otimização baseada em gradiente.

A. Rede Neural Siamesa profunda

No início de 1990 para resolver a verificação de assinatura como um problema de correspondência de imagens, as redes neurais siamesas foram introduzidas pela primeira vez por [Bromley et al. 1993]. Uma rede neural siamesa consiste em redes gêmeas que aceitam entradas distintas, mas são unidas por uma função de energia no topo. Esta função calcula alguma métrica entre a representação dos níveis de características mais alto de cada lado conforme exemplificado na Figura 1.

Os parâmetros entre as redes gêmeas estão vinculados. A amarração dos pesos garantem que duas imagens, não extremamente semelhantes, sejam mapeadas por suas respectivas redes para locais muito diferentes no espaço, porque cada rede calcula a mesma função. Além disso, a rede é simétrica, de modo que sempre que apresentamos duas imagens distintas à redes gêmeas, a camada de junção superior irá calcular a mesma métrica, como se apresentássemos as duas imagens, mas para os gêmeos opostos. Em [Chopra et al. 2005] os autores usaram uma função de energia contrastiva que continha

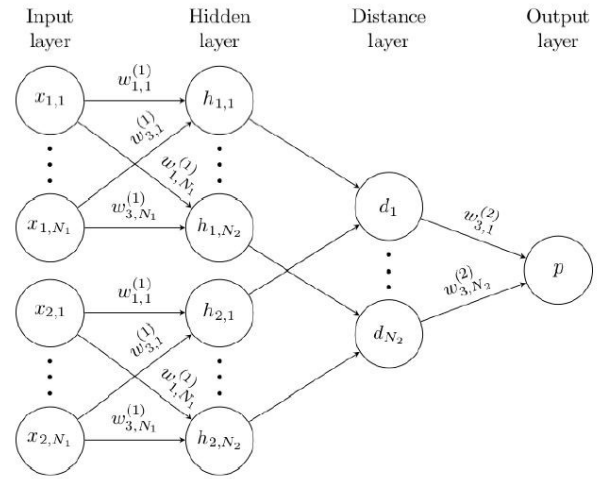


Fig. 1. Exemplo de rede neural Siamesa

termos duais para diminuir a energia de pares semelhantes e aumentar a energia de pares diferentes. Assim, um objetivo de entropia cruzada é uma escolha natural para treinamento a rede. Observe que em [Chopra et al. 2005], eles diretamente aprenderam a métrica de similaridade, que foi implicitamente definida pela perda de energia, enquanto fixaram as métricas.

V. MATERIAIS E MÉTODOS

Seguem os materiais e métodos utilizados para a elaboração do trabalho.

A. Equipamento

Utilizou-se equipamentos de ressonância magnética nuclear de extremidades, de alto campo magnético, de intensidade de 1 Tesla.

B. Phantom

Para a aquisição de imagens utiliza-se um cubo de material plástico/ acrílico (semelhante à uma garrafa) contendo água desmineralizada somada de sulfato de cobre em conhecida proporção. Ao ser aplicada a essa solução um campo magnético, e em seguida pulsos de rádio frequência, a mesma, responderá ao sistema de ressonância magnética com uma certa quantidade de energia, que será captada pela bobina de rádio frequência do equipamento. E, por ser conhecida a concentração da solução de dentro do *Phantom*, pode-se estimar a resposta do *Phantom*, e assim determinar se o equipamento se encontra dentro das características corretas para seu funcionamento.

C. Imagens

As imagens, resultantes das aquisições, tem aspectos muito parecidos e correspondem à uma figura circular na região central, que representa a área de um corte axial realizado no *Phantom*. Um quadrado, na parte interna da figura circular da região central, indica a área de aquisição do sinal da imagem chamado *IS (Intensity Signal)*. Quatro retângulos, localizados em volta da figura central da imagem e dentro do fundo

preto, sendo que, dois, situados à direita e à esquerda da figura central, representam a área de onde foram retirados os dados referentes ao ruído das imagens, e dois, situados na parte superior e inferior da figura central, representam a área de onde foram retirados os dados de uma possível vibração no magneto, que pode ser devido a bobina de gradiente mal fixada, ou vibração estrutural de onde o magneto está instalado. A Figura 2 ilustra como é realizada a retirada as informações das amostras das imagens de *Phantom* padrão.




Fig. 2. Análise da Imagem de *Phantom*

D. Protocolo de Aquisição

DQA (Daily Quality Assurance) [Oni 2003] é um protocolo utilizado para aquisição e análise de imagens, utilizado para verificar as condições técnicas e confirmar se o equipamento está calibrado, e apto para a realização de exames e que foi o padrão utilizado na realização do trabalho. O *DQA* define os seguintes parâmetros: tempo de aquisição de 4:19 minutos; 256 linhas x 256 colunas de aquisição; relação do *FOV (Field of Vision)* de 1 (número de linhas iguais ao número de colunas); espessura do corte em 5mm; *FOV* de 140mm; *Nex* igual a 1 (quantidade de vezes que um *voxel* será coletado e analisado); tempo de relaxamento de 1000 ms (tempo de retorno do *Spin* à posição inicial); tempo de excitação de 20ms; tempo de excitação do *spin* com RF) e banda passante de 25kHz. E, em conjunto com o *DQA*, foi utilizada uma bobina de 180mm de diâmetro, porque o tamanho da bobina interfere diretamente na relação da *SNR*.

E. Definição do número de imagens

Através do protocolo *DQA* foram coletadas 53 imagens de 3 equipamentos de ressonância de extremidades de mesmo modelo, de intensidade de campo de 1.0T instalados em locais diferentes. As imagens foram classificadas em calibradas e fora de calibração, por um especialista em equipamentos de ressonância magnética considerando os seguintes critérios: apresentar geometria característica da imagem de *Phantom*;

não ter artefatos; não apresentar ruído na imagem e ter homogeneidade na área que representa o *Phantom*. Nas Figuras 3 e 4 estão as imagens estudadas.



Fig. 3. Imagens calibradas




Fig. 4. Imagens fora de calibração

F. Processo de medida da *SNR* pelo equipamento

Através do protocolo *DQA*, o equipamento automaticamente realiza os cálculos para verificar se as imagens estão dentro ou fora do padrão de qualidade, especificado pelo fabricante. Para uma bobina de 180mm o *DQA* deve apresentar uma *SNR* acima de 105.

G. Aprendizado de poucas amostras (*FSL*)

Neste artigo, propomos uma Rede Siamesa formada por uma *VGG11* que foi treinada no conjunto ImageNet. A *VGG11* formará um tensor de características ($512 \times 7 \times 7$) e redimensionado para um vetor de 25088 informações que representa o extrator de características. Os valores das primeiras camadas da *CNN* representam os atributos não semânticos (como cor, contornos, ...) e as últimas camadas são os atributos mais complexos. Os resultados são dois vetores que serão subtraídos um do outro e o resultado final servirá de entrada para uma rede totalmente conectada (*Full connected*) de 25088 neurônios. A saída da rede totalmente conectada será aplicada a uma função sigmoide gerando um valor entre 0 e 1 que indicará a comparação entre as figuras. A estrutura geral do aprendizado de poucas amostras é dado na Figura 5.




Fig. 5. *Few Shot Learning*

VI. EXPERIMENTOS

Para a realização deste trabalho foram utilizadas imagens de *Phantom* calibradas e fora de calibração, classificadas por um especialista em equipamentos e imagens de ressonância magnética.

A. Entradas

Foram escolhidas um total de 53 imagens de *Phantom* separadas em Calibradas e Fora de Calibração. Estas 53 imagens foram separadas em treinamento, validação e teste. O conjunto de treinamento foi elaborado através de 60% do conjunto de 53 imagens, totalizando 32 imagens. O conjunto de validação foi elaborado através de 20% do conjunto de 53 imagens, totalizando 11 imagens. O conjunto de teste foi elaborado através de 20% do conjunto de 53 imagens, totalizando 10 imagens, sendo 5 calibradas e 5 fora de calibração, fixas, conhecidas e imutáveis. As 32 imagens de treinamento, considerando duas entradas na Rede Siamesa, formarão 992 combinações de entrada de treinamento (N entradas \times $N-1$ entradas) ($32 \times 31 = 992$). Considerando o mesmo raciocínio, haverá 110 combinações de validação e 100 combinações de teste. A *Table I* apresenta as entradas da Rede *FSL*.

TABLE I
Dados das Imagens

Imagens	Conjunto	%	Qtde	Combinações
53	Treinamento	60	32	992
	Validação	20	11	110
	Teste	20	10	calibradas e fora de calibração (aleatórias)
	Suporte		5b e 5r	5 calibradas e 5 fora de calibração

B. FSL

O trabalho foi realizado em *2-way 5-shot*, ou seja, a resposta do sistema foi separada em duas respostas distintas, calibradas e fora de calibração. O termo *5-shot* representa que foram utilizadas de 1 à 5 imagens para suporte (5 calibradas e 5 fora de calibração). O treinamento e validação foi realizado com um *bath size* de 128 e *k-fold* de 10.

VII. RESULTADOS E DISCUSSÕES

Segue na *Table II* os resultados coletados pelos dados aplicados na Rede *FSL*.

Como haveria de se esperar, os resultados para 2 ou mais imagens de suporte são superiores de quando apenas uma imagem de suporte é utilizada, quando a acurácia de teste

TABLE II
Acurácia de Teste

	Shot	Acurácia (ACC)
1	[1-shot]	0,65 \pm 0,15
2	[2-shot]	0,77 \pm 0,19
3	[3-shot]	0,97 \pm 0,04583
4	[4-shot]	0,97 \pm 0,04583
5	[5-shot]	0,97 \pm 0,04583

foi de 0,65 \pm 0,15. Para duas imagens de suporte a acurácia de teste foi de 0,77 \pm 0,19. Notou-se que para 3 ou mais imagens de suporte, o resultado permaneceu o mesmo com 0,97 \pm 0,04583 de assertividade.

VIII. CONCLUSÃO

A base de imagens utilizada para o estudo foi de 53 imagens, e os resultados obtidos foram extremamente satisfatórios principalmente para 3 ou mais imagens de teste.

Como verificado, o uso do *Few Shot Learning* e *SNR* na análise das imagens de phantom, garantem uma confiabilidade muito maior na avaliação da qualidade da calibração do equipamento. Todos os equipamentos deveriam incorporar ao seu software, o código de *FSL* para a análise da qualidade da calibração da imagem, permitindo que o equipamento realize exames, apenas após ser aprovado pelos dois processos de avaliação da qualidade de calibração do equipamento, a *SNR* e o *FSL*.

O processo de *Few Shot Learning* além de resultados proeminentes, levou em consideração a geometria, posicionamento, artefatos, analisando a imagem de *Phantom* de uma forma completa, como o especialista realiza.

A resposta deste trabalho apresentou uma melhor acurácia se comparado com o processo de (*PCA+MLDA*) apresentado por [Andrioli and Thomaz 2021] em 2021.

O trabalho limitou-se a estudar e realizar a análise de imagens em equipamentos de ressonância magnética de extremidades de 1.0T (campo alto), pelo fato de se conhecer o especialista nesse tipo de equipamento, mas poderá ser aplicado em outros equipamentos radiológicos de imagem, e em outras imagens patológicas, desde que acompanhado sempre por um especialista.

A base de dados atual encontra-se disponível de forma aberta para novos trabalhos e como sugestão, propõe-se a análise dos ruídos ocasionados por outros fatores, como interferência ferromagnética, vibração, temperatura da sala, entre outros.

REFERENCES

- [Andrioli and Thomaz 2021] Andrioli, C. J. and Thomaz, C. E. (2021). Discriminant analysis of background noise in extremity magnetic resonance images. *Anais do XVII Workshop de Visão Computacional (WVC 2021)*.
- [Bromley et al. 1993] Bromley, J., Bentz, J. W., Bottou, L., Guyon, I., LeCun, Y., Moore, C., Säckinger, E., and Shah, R. (1993). Signature verification using a "siamese" time delay neural network. In *Int. J. Pattern Recognit. Artif. Intell.*
- [Chopra et al. 2005] Chopra, S., Hadsell, R., and LeCun, Y. (2005). Learning a similarity metric discriminatively, with application to face verification. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR '05)*, 1:539–546 vol. 1.

- [Constantinides et al. 1997] Constantinides, C., Atalar, E., and McVeigh, E. R. (1997). Signal-to-noise measurements in magnitude images from nmr phased arrays. *Magnetic Resonance in Medicine*, 36:852–857.
- [Cortes and Vapnik 2004] Cortes, C. and Vapnik, V. N. (2004). Support-vector networks. *Machine Learning*, 20:273–297.
- [Dahia and Segundo 2020] Dahia, G. and Segundo, M. P. (2020). Meta learning for few-shot one-class classification. *ArXiv*, abs/2009.05353.
- [Dietrich et al. 2007] Dietrich, O., Raya, J. G., Reeder, S. B., Reiser, M., and Schoenberg, S. O. (2007). Measurement of signal-to-noise ratios in mr images: Influence of multichannel coils, parallel imaging, and reconstruction filters. *Journal of Magnetic Resonance Imaging*, 26.
- [Fei-Fei et al. 2006] Fei-Fei, L., Fergus, R., and Perona, P. (2006). One-shot learning of object categories. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28:594–611.
- [Fisher 1936] Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2):179–188.
- [Giraldi et al. 2008] Giraldi, G., Thomaz, C., and Rodrigues, P. (2008). *Dimensionality reduction, classification and reconstruction problems in statistical learning approaches*. Revista de Informatica Teórica e Aplicada.
- [Goerner and Clarke 2011] Goerner, F. L. and Clarke, G. D. (2011). Measuring signal to noise ratio in partially parallel imaging mri. *Medical Physics*, 38:5049–5057.
- [Guerin et al. 2017] Guerin, B., Villena, J. F., Polimeridis, A. G., Adalsteinsson, E., Daniel, L., White, J. K., and Wald, L. L. (2017). The ultimate signal-to-noise ratio in realistic body models. *Magnetic Resonance in Medicine*, 78:1969–1980.
- [Hastie et al. 2009] Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference and Prediction*. Springer.
- [Janousova et al. 2015] Janousova, E., Schwarz, D., and Kasperek, T. (2015). Combining various types of classifiers and features extracted from magnetic resonance imaging data in schizophrenia recognition. *Psychiatry Research: Neuroimaging*, 232:237–249.
- [Koch 2015] Koch, G. R. (2015). Siamese neural networks for one-shot image recognition.
- [Koriwakova et al. 2010] Koriwakova, E., Schwarz, D., and Kaparek, T. (2010). Classification of 3-d mri brain data using modified maximum uncertainty linear discriminant analysis.
- [Kuperman 2000] Kuperman, V. (2000). *Magnetic Resonance Imaging*. Academic Press.
- [Lake et al. 2011] Lake, B. M., Salakhutdinov, R., Gross, J., and Tenenbaum, J. B. (2011). One shot learning of simple visual concepts. *Cognitive Science*, 33.
- [Lee et al. 2019] Lee, K., Maji, S., Ravichandran, A., and Soatto, S. (2019). Meta-learning with differentiable convex optimization. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 10649–10657.
- [Liu 2016] Liu, T. T. (2016). Noise contributions to the fmri signal: An overview. *NeuroImage*, 143:141–151.
- [Marcovski 1996] Marcovski, A. (1996). Noise in mri. *Magnetic Resonance in Medicine*, 36:494–497.
- [McRobbie et al. 2006] McRobbie, D., Moore, E., Graves, M., and Prince, M. (2006). *Mri from picture to proton*. Academic Press.
- [Oni 2003] Oni (2003). Optimizing image quality.
- [Pang and Mak 2015] Pang, X. and Mak, M.-W. (2015). Noise robust speaker verification via the fusion of snr-independent and snr-dependent plda. *International Journal of Speech Technology*, 18:633–648.
- [Sato et al. 2009] Sato, J. R., Fujita, A., Thomaz, C. E. and Martin, M. G. M., Mourão, M. J., Brammer, M. J., and Junior, E. A. (2009). Evaluating svm and mlda in the extraction of discriminant regions for mental state prediction. *Neuroimage*, 46(1):105–114.
- [Schnell et al. 2000] Schnell, W. D., Renz, W., Vester, M. D., and Ermert, H. (2000). Ultimate signal-to-noise-ratio of surface and body antennas for magnetic resonance imaging. *IEEE Transactions on Antennas and Propagation*, 48:418–428.
- [Sharma 2017] Sharma, N. (2017). Single-trial p300 classification using pca with lda, qda and neural networks. *ArXiv*, abs/1712.01977.
- [Snell et al. 2017] Snell, J., Swersky, K., and Zemel, R. S. (2017). Prototypical networks for few-shot learning. *ArXiv*, abs/1703.05175.
- [Thomaz and Gillies 2006] Thomaz, C.E. and Kitani, C. and Gillies, D. (2006). A maximum uncertainty lda-based approach for limited sample size problems - with application to face recognition. *Journal of the Brazilian Computer Society (JBACS)*, 12(2):7–18.
- [Vaughan et al. 2001] Vaughan, J. J. T., Garwood, M., Collins, C. M., Liu, W., DelaBarre, L., Adriany, G., Andersen, P., Merkle, H., Goebel, R., Smith, M., and Uğurbil, K. (2001). 7t vs. 4t: Rf power, homogeneity, and signal-to-noise comparison in head images. *Magnetic Resonance in Medicine*, 46.
- [Wang et al. 2022] Wang, D., Robison, R. K., Li, Z., and Pipe, J. G. (2022). High snr rapid t1-weighted mprage using spiral imaging with long readouts and improved deblurring. *Magnetic resonance in medicine*.
- [Xia et al. 2021] Xia, C., Xiong, C., and Yu, P. S. (2021). Pseudo siamese network for few-shot intent generation. *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*.