

Status da modelagem computacional do experimento cygno

Guilherme Sebastião Pinheiro Lopes



27 de Março de 2019



Sumário



- ❑ Caracterização do ruído
- ❑ Extração de parâmetros dos traços

Caracterização do ruído

Caracterização do ruído

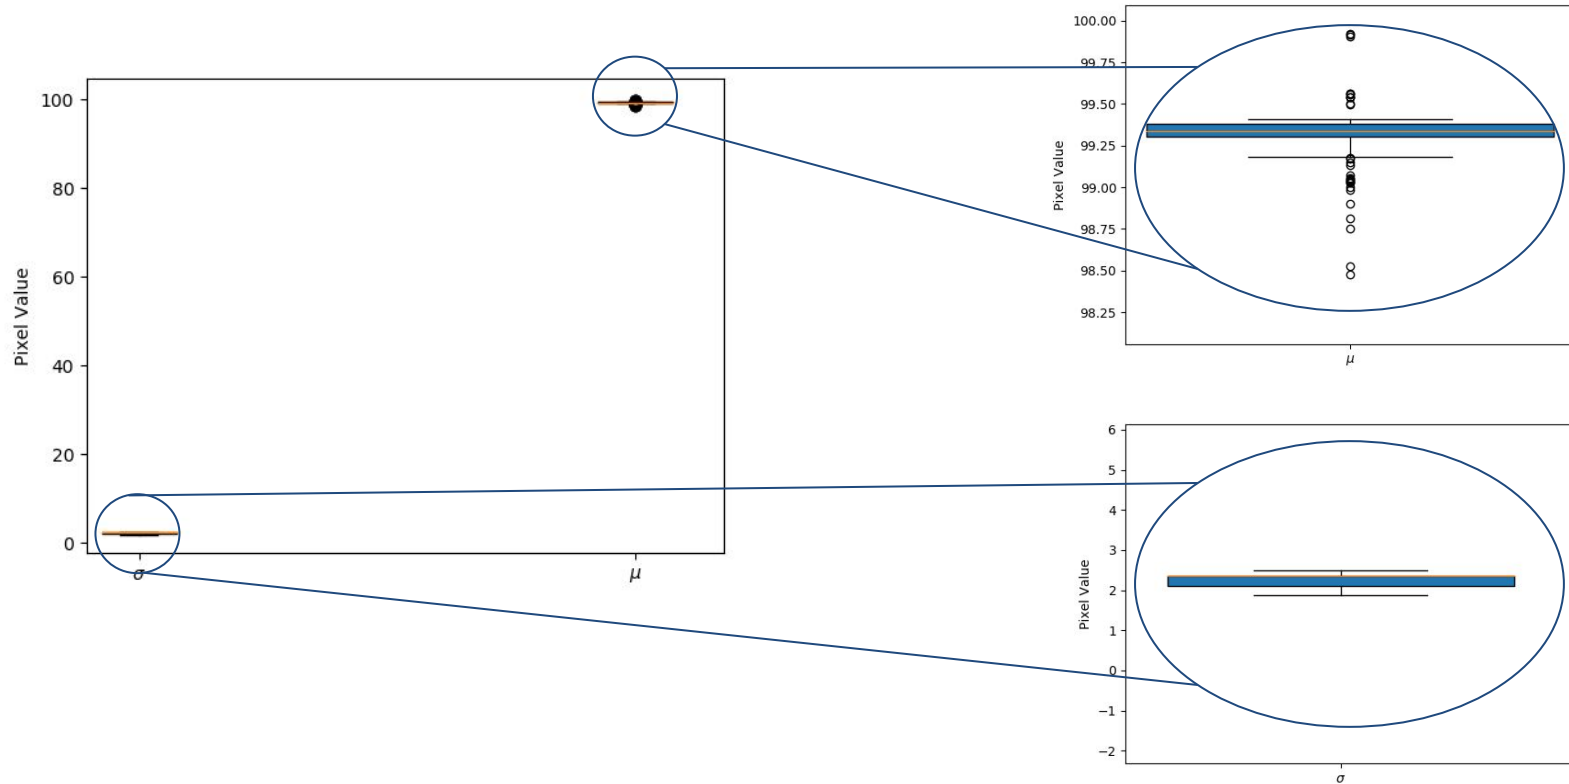
Utilizando a run 497(5 imagens de ruído):

$$f(x) = f_g(x) + f_e(x)$$




Caracterização do ruído

Parâmetros da Gaussiana



Caracterização do ruído

Parâmetro da Exponencial




Extração de parâmetros dos traços

- ❑ Seleção manual das imagens via python
- ❑ Rotação das imagens selecionadas para centralização
- ❑ Filtro Gaussiano para suavização
- ❑ Análise das médias(linha,coluna)
- ❑ Extração de largura e comprimento
- ❑ Modelagem da função de degradação


Extração de parâmetros dos traços

- ❑ Seleção manual das imagens via python




Extração de parâmetros dos traços

- ❑ Rotação das imagens selecionadas para centralização





Extração de parâmetros dos traços

- ❑ Filtro Gaussiano(máscara = 4)




Extração de parâmetros dos traços

☐ Análise das médias





Extração de parâmetros dos traços

- Análise dos tracks
- Alto contraste



Extração de parâmetros dos traços

- ☐ Análise dos tracks
- ☐ Alto contraste








Extração de parâmetros dos traços



Análise dos tracks





Contraste médio





Extração de parâmetros dos traços





☐ Análise dos tracks

☐ Contraste médio



Extração de parâmetros dos traços




-  Análise dos tracks
-  Baixo contraste



Extração de parâmetros dos traços

☐ Análise dos tracks

☐ Contraste médio




Extração de parâmetros dos traços

- ❑ Análise dos tracks
 - ❑ Devido a difícil tarefa de mapear os thresholds para os diversos tipos de dados foi decidido medir os traços manualmente, definir as melhores técnicas de pré-processamento para este experimento e retomar esta análise futuramente(devido a importância de caracterizar a degradação).

Extração de parâmetros dos traços

- ❏ Extraíndo parâmetros dos tracks(somente retas)




Extração de parâmetros dos traços


- ❏ O banco de dados das medidas são encontrados em:
<https://docs.google.com/spreadsheets/d/1gTKmBRjng2EMX2C3vLt1EKMgriyFqTFhpXB4Xb2U0cw/edit#gid=0>

Extração de parâmetros dos traços



■ Histogramas dos dados coletados:





Geração de traços





Geração de traços



Geração de traços




Geração de traços



Atualizações


Davide sugeriu algumas modificações:

- Utilizar o truth(**peloto**) deixou as imagens muito artificiais.
- Inserir efeito de borda
- Aplicar poisson nos pixels acesos



- Tracks diferentes
- Mudança na nossa definição de truth

Uma solução:
Truth um pouco maior...






Outra solução:

- Um truth para a reta geradora do track
- Outro para a energia do track



Distribuição de energia no track

Como é:



Distribuição de energia no track


Como deve ser..




Implementação

- ❑ A simetria ocorre devido a o espaço entre as gaussianas que geram o track ser uniforme;
- ❑ Uma das soluções pode ser obtida variando a distância entre estes pontos;
- ❑ Pode-se usar distribuições de probabilidade para aplicação deste efeito.


Exemplo: Linspace




Exemplo: Rayleigh



Exemplo: Gamma



Exemplo: Lognormal




Implementação

- ❑ Para os exemplos anteriores foram utilizados distribuições paramétricas;
- ❑ O algoritmo viabiliza a implementação de distribuições não paramétricas onde a curva desejada é o parâmetro de entrada.

Criando tracks curvos

- ❑ Outra possibilidade é distribuir o centro das gaussianas de forma curva (por um polinômio por exemplo).



Novas sugestões

- ❑ Estudo da correlação entre os pixels nas imagens de ruído;
- ❑ Analisar outras simulações existentes na colaboração;
- ❑ Energia como medida de performance.

Estudo da correlação entre pixels





Padronizado pelo
experimento

Run	Tempo de exposição(ms)
817	10
818	100
819	1000
820	1000

Estudo da correlação entre pixels

❑ Coluna como uma v.a




- Cada coluna tem uma v.a associada!!
- Conseguimos obter a relação entre os vizinhos (laterais) medindo a correlação entre as va's.


Estudo da correlação entre pixels

- Coluna como uma v.a (Matriz de covariância para uma imagem)

Spikes muito loucos
Pq será?



Parece que alguns
pixels apresentam
correlação.






Estudo da correlação entre pixels

❑ Coluna como uma v.a(Exemplo para uma imagem)

Qual é a posição destes spikes?

-Aumentando os limites do plot..




Estudo da correlação entre pixels

❑ Coluna como uma v.a(Matriz de covariância)


Antes de tentar entender o problema vamos aumentar o número de amostras(mais imagens).

->Run 817


10 imagens



50 imagens



100 imagens




Estudo da correlação entre pixels

❑ Coluna como uma v.a(Matriz de covariância)


Antes de tentar entender o problema vamos aumentar o número de amostras(mais imagens).

->Run 818


10 imagens



50 imagens



100 imagens




Estudo da correlação entre pixels

❑ Coluna como uma v.a(Matriz de covariância)


Antes de tentar entender o problema vamos aumentar o número de amostras(mais imagens).

->Run 819


10 imagens



50 imagens



100 imagens




Estudo da correlação entre pixels

❑ Coluna como uma v.a (Matriz de covariância)


Antes de tentar entender o problema vamos aumentar o número de amostras (mais imagens).

-> Run 820


10 imagens



50 imagens



100 imagens




Estudo da correlação entre pixels

❑ Coluna como uma v.a

Será que as imagens explicam esse comportamento?

-> Selecionando algumas imagens aleatórias no banco de dados: 817




Estudo da correlação entre pixels

❑ Coluna como uma v.a

Será que as imagens explicam esse comportamento?

-> Selecionando algumas imagens aleatórias no banco de dados: 818




Estudo da correlação entre pixels

❑ Coluna como uma v.a

Será que as imagens explicam esse comportamento?

-> Selecionando algumas imagens aleatórias no banco de dados: 819




Estudo da correlação entre pixels

❑ Coluna como uma v.a

Será que as imagens explicam esse comportamento?

-> Selecionando algumas imagens aleatórias no banco de dados: 820







Estudo da correlação entre pixels

❑ Linha como uma v.a (Matriz de covariância)

Analizando todos os runs com 100 imagens.

-Parece que as linhas são descorrelacionadas(exceto no run 820)..



Conclusões parciais

- ❑ Considerando que o tempo exposição 100 ms;
 - ❑ As linhas podem ser geradas de forma independente
 - ❑ As colunas não...
 - Como podem ser geradas??
 - Se forem gaussianas é possível a partir da matriz de covariância(mas acho que não são)