

APRESENTAÇÃO FINAL DE PSI3571

Grupo II – Fernando, João e Thomas

1

GRUPO 02 — PSI3571 — PRÁTICAS EM RECONHECIMENTO DE PADRÕES, MODELAGEM E INTELIGÊNCIA COMPUTACIONAL

Escola politécnica da Universidade de São Paulo

- Fernando Rossato França – 5º ano PSI
- João Lucas S Martins – 5º ano PSI
- Thomas Araújo Muiyal – 5º ano PSI

GRUPO 02 — DIVISÃO DE TAREFAS

- Cada membro responsabilizou-se por um projeto;
- Todos os membros se disponibilizaram para ajuda mútua.

PROJETOS

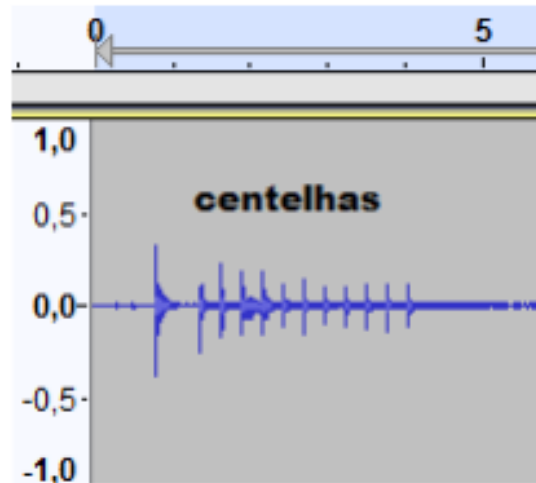
- Reconhecedor de faces;
- Reconhecedor de eventos em ambientes residenciais;
- Controle de Drones.

RECONHECEDOR RESIDENCIAL


- Variáveis de entrada:
 - Sinal de áudio (microfone de *smartphone*);
 - ~~Temperatura (termopar);~~
 - ~~Vibrações (acelerômetro).~~
- Analisar janelas de 1 segundo;
- Amostragem de ~~17 kHz~~ 3 Hz se mostrou suficiente.

RECONHECEDOR RESIDENCIAL


- Evento ilustrativo: acender fogão a gás
 - Som das centelhas;



RECONHECEDOR RESIDENCIAL



test.dat			
Arquivo Editar Formatar			
Exibir Ajuda			
0	0	35	1
0	0	3	0
0	0	17	1
0	0	34	1
0	0	32	1



Taxa de erro: 80%


RECONHECEDOR RESIDENCIAL

- Alternativa ao RMS
 - Função de custo da média do módulo do erro

$$J_{EBM} = \frac{\sum_{i=1}^N |t_i - y_i|}{N} = \frac{\sum_{i=1}^N |e_i|}{N}$$

RECONHECEDOR RESIDENCIAL


- Resultados do ensaio 50+50 amostras




RECONHECEDOR RESIDENCIAL

- Otimização


- Redes com diferentes graus de complexidade para evitar sobre aprendizado.



Sem s.a.



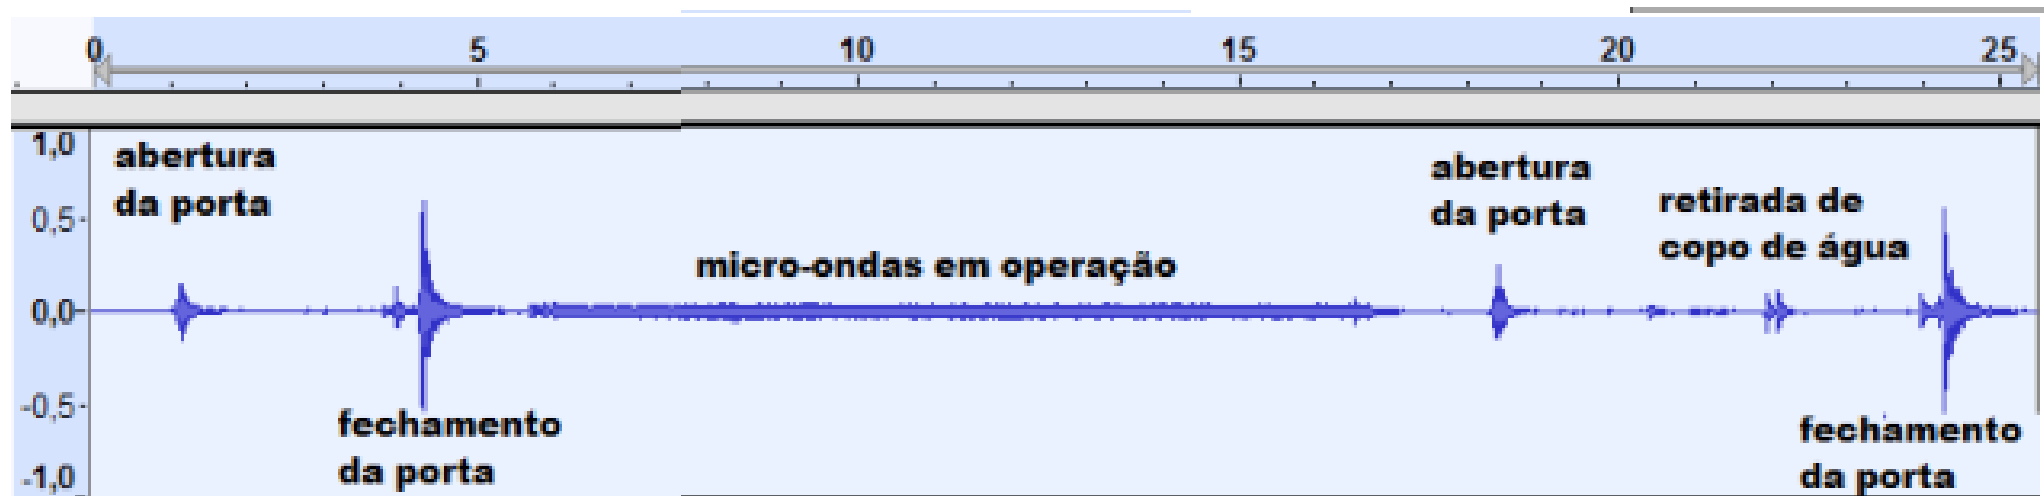
Sinais de s.a.



Sutil s.a.

RECONHECEDOR RESIDENCIAL

- Direção para continuação do projeto
 - Identificação sequencial de eventos



RECONHECEDOR FACIAL

OBJETIVOS:

- Reconhecer rostos de indivíduos cadastrados em um banco de dados.
- Implementar um sistema inteligente de aprendizado supervisionado.
- Expandir os horizontes para novos métodos computacionais além das redes neurais convencionais.

RECONHECEDOR FACIAL

MÉTODO:

- Pré-processamento (resize p/ 168x192 e 92x112 e conversão p/ grayscale).
- LBPH para extração de features.
- Distância euclidiana entre a imagem teste e imagens de treino (banco de dados).
- Algoritmo compara histograma concatenado de Local Binary Patterns entre teste e treino e seleciona o label com menor distância euclidiana.

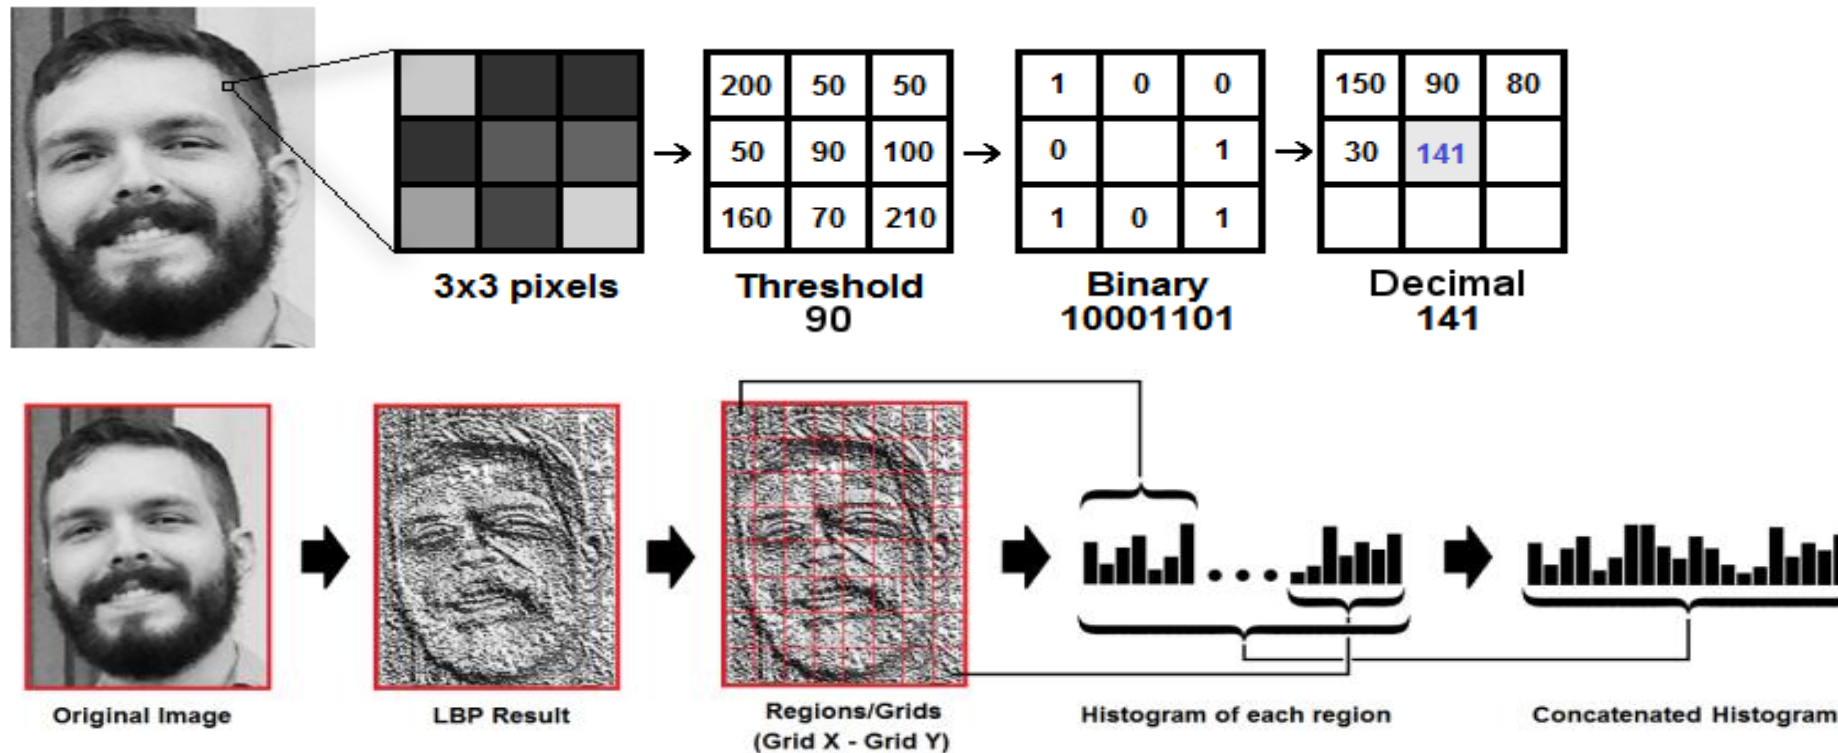
RECONHECEDOR FACIAL

LBPH o que é?

- LBPH é um método de extração de features que permite que o computador “entenda” o relevo de uma imagem.
- É útil para analisar imagens de forma invariante a iluminação.

RECONHECEDOR FACIAL


LBPH o que é?



RECONHECEDOR FACIAL

LBPH o que é?

Para 92×112 , a imagem é dividida em 16 partes.
Para 168×192 , a imagem é dividida em 64 partes



RECONHECEDOR FACIAL

Banco de dados:

- Att_faces = 40 pessoas, cada uma com 10 fotos faciais. Total de imagens: 400.
- Cropped_yale = 40 pessoas, cada uma com 64 fotos faciais. Total de imagens: 2560.
- Fonte: Universidade Yale e AT&T Laboratories.

RECONHECEDOR FACIAL

Resultados :

- Medida de erro: realiza Leave One Out e conta o número de acertos. No final, calcula a razão acertos / total de análises.
- Foram realizados 2 testes no att_faces e 2 testes no cropped_yale.
- N = 40 1° teste 400 2° teste att_faces e 256 1° teste 2560 2° teste cropped_yale.

RECONHECEDOR FACIAL

Resultados :

```
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.984772 %
++ INICIO ++
Faltam: 6 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.987343 %
++ INICIO ++
Faltam: 5 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.989899 %
++ INICIO ++
Faltam: 4 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.992447 %
++ INICIO ++
Faltam: 3 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.994980 %
++ INICIO ++
Faltam: 2 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 98.997490 %
++ INICIO ++
Faltam: 1 imagens
0 label real dessa iteracao e': 12
0 label previsto e': 12
A porcentagem atual de acertos e': 99.000000 %
A porcentagem final de acertos e':
99 %
Arquivo s28/8.pgm. Correta=27. Classificada=36
Arquivo s26/2.pgm. Correta=25. Classificada=4
Arquivo s5/10.pgm. Correta=4. Classificada=17
Arquivo s10/10.pgm. Correta=9. Classificada=8
```

RECONHECEDOR FACIAL

Resultados :

- att_faces/quatro.txt >> 100% de acerto. Calcula rápido. 4 pessoas x 10 imagens
- att_faces/todos.txt >> 99% de acerto. Demora alguns minutos. 40 pessoas x 10 imagens
- cropped_yale/quatro.txt >> 97.65% de acerto. Demora alguns minutos. (Demora mais do que o att_faces) 4 pessoas x 64 imagens
- cropped_yale/todos.txt >> Arquivo muito extenso, processamento demora na ordem de dezenas de horas (29 horas aproximadamente). Faltando 2285 imagens, a taxa de acerto era de 92.48%. (Programa havia rodado 1 hora e 30 minutos aproximadamente) 40 pessoas x 64 imagens

RECONHECEDOR FACIAL

Resultados :

```
0 label previsto e': 36
A porcentagem atual de acertos e': 91.549294 %
++ INICIO ++
Faltam: 2343 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 91.666672 %
++ INICIO ++
Faltam: 2342 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 91.780823 %
++ INICIO ++
Faltam: 2341 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 91.891891 %
++ INICIO ++
Faltam: 2340 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 92.000000 %
++ INICIO ++
Faltam: 2339 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 92.105263 %
++ INICIO ++
Faltam: 2338 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 92.207787 %
++ INICIO ++
Faltam: 2337 imagens
0 label real dessa iteracao e': 36
0 label previsto e': 36
A porcentagem atual de acertos e': 92.307693 %
++ INICIO ++
Faltam: 2336 imagens
0 label real dessa iteracao e': 36
```

RECONHECEDOR FACIAL

Conclusão:

- LBPH é um reconhecedor bem eficiente e rapido.
- Pre-processamento (detecção, resize e rotação) é requerido.
- Invariante a iluminação


RECONHECEDOR FACIAL

Bibliografia :

- <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html> - Site Oficial do Dataset “att_faces”
- <http://vision.ucsd.edu/~iskwak/ExtYaleDatabase/ExtYaleB.html> - Site para download do Dataset B “cropped_yale”


CONTROLE DE DRONES

- Foi desenvolvido uma implementação de controle Proporcional, Integrativo e Derivativo (PID) para o controle de atitude (ângulo) de um drone quadricóptero
- Deseja-se controlar a atuação nos motores de modo a manter estabilidade e levar o drone até uma posição alvo




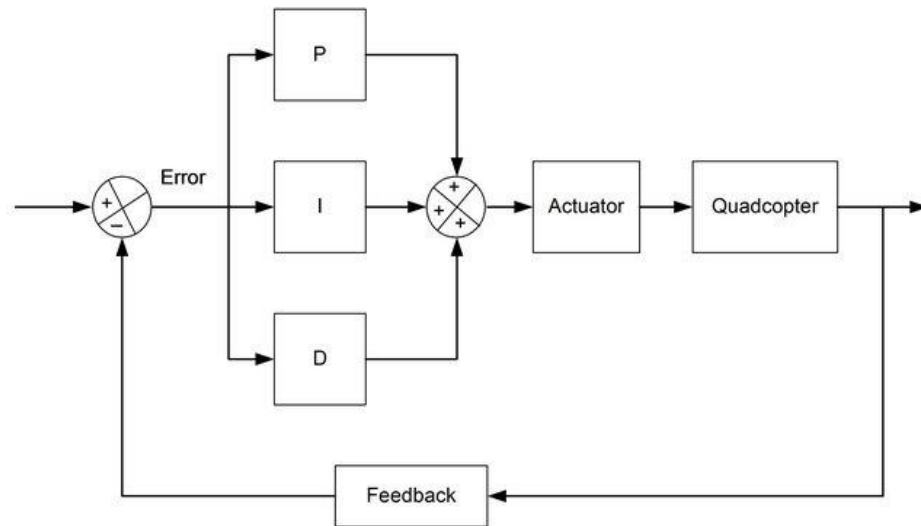
CONTROLE DE DRONES

- Variáveis de entrada:
 - Altitude (z)
 - Ângulo (ϕ , ψ , θ)
 - RPM dos motores (RPM1, RPM2, RPM3, RPM4)
 - Valores alvo de altitude e ângulo ($targetz$, $targetphi$, $targetpsi$, $targettheta$)
- Saídas
 - Atuação nos motores, de 0% a 100% ($throttle1$, $throttle2$, $throttle3$, $throttle4$)



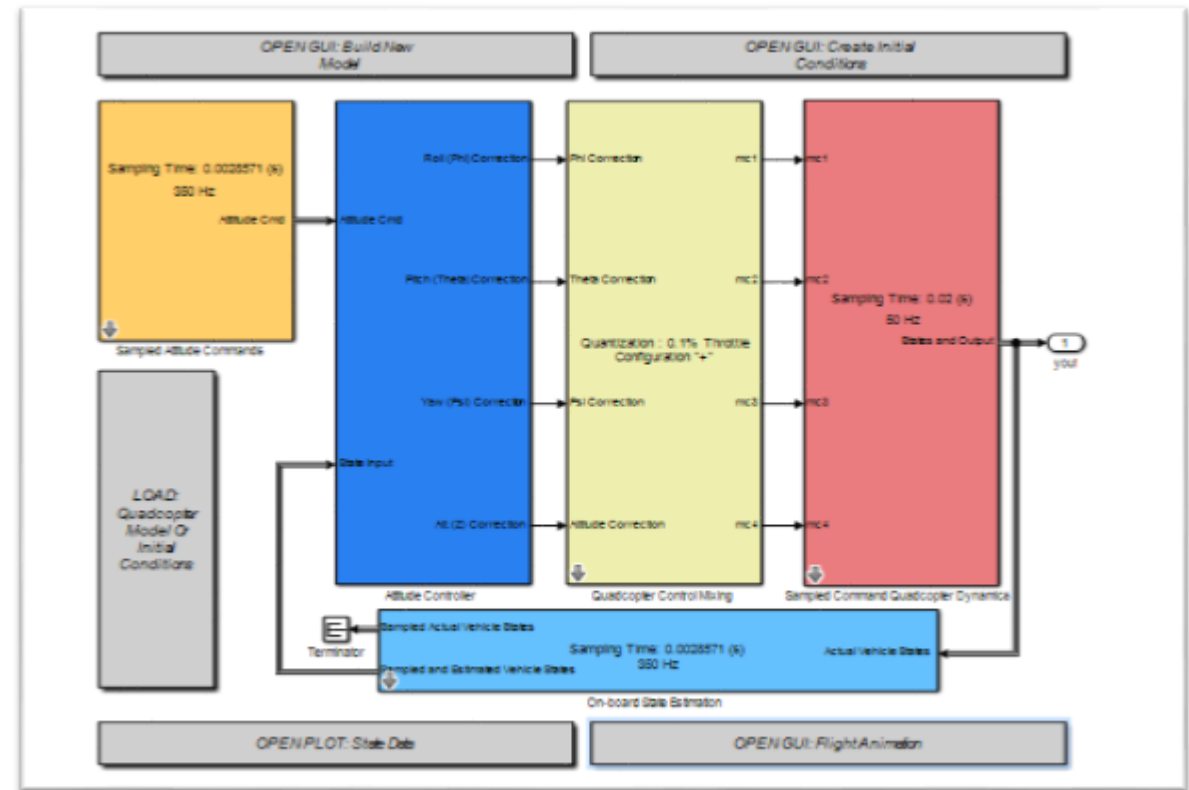
CONTROLE DE DRONES

- Método escolhido foi utilizar uma rede neural que aprenda as respostas que um controle PID daria para determinadas situações



CONTROLE DE DRONES

- Foi utilizado o Quadsim, que é um modelo em Simulink/MATLAB que implementa:
 - Modelos físicos de drones quadricópteros;
 - Controle de atitude e posição de drones de um controlador PID (Proporcional, Integrativo e Derivativo)
 - Mixagem de sinais, cálculo de erro de trajetória e simulador



CONTROLE DE DRONES

- Foram consideradas como variáveis de entrada dados já usados pelo controle do Quadsim, além de dados que seriam captados com sensores realizáveis numa implementação real, como RPM

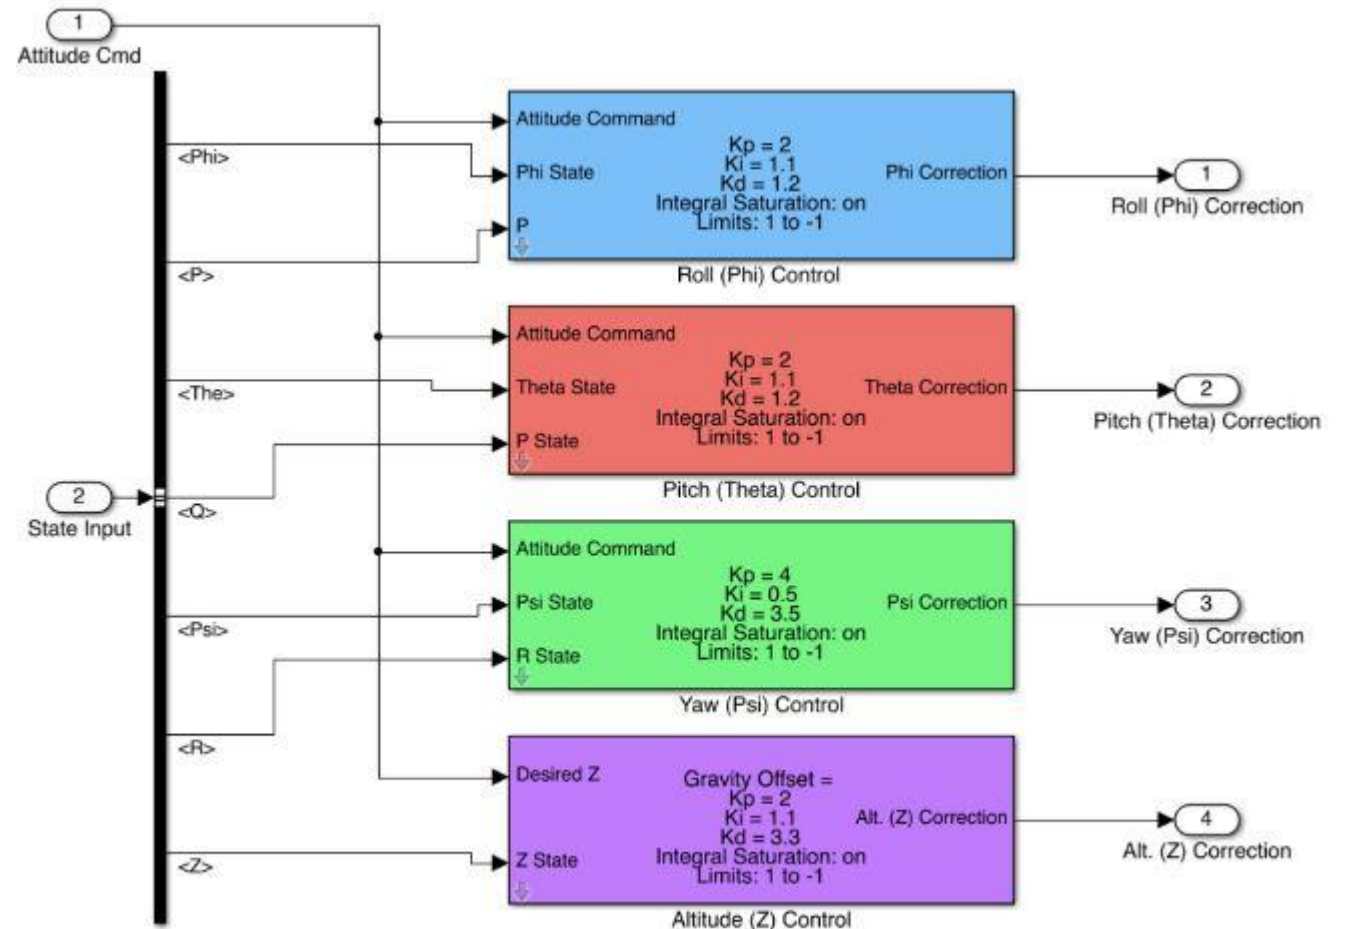


Figure 2. Attitude control block interior

CONTROLE DE DRONES

- O controle PID foi isolado e extraído do simulador/controlador
- Foram injetados sinais de entrada advindos de resultados de simulações com diversas condições iniciais e alvos finais
- Os resultados da injeção destes dados consistem no conjunto de saídas esperadas do controle





Figure 2. Attitude control block interior


CONTROLE DE DRONES

EXPECTATIVA

- O simulador fornece como saída todos os valores numéricos de todas as variáveis em instantes espaçados em 0.001s.
- Também fornece gráficos com a atuação nos motores (azul) e a velocidade dos motores (vermelho)
- Espera-se obter gráficos de atuação similares

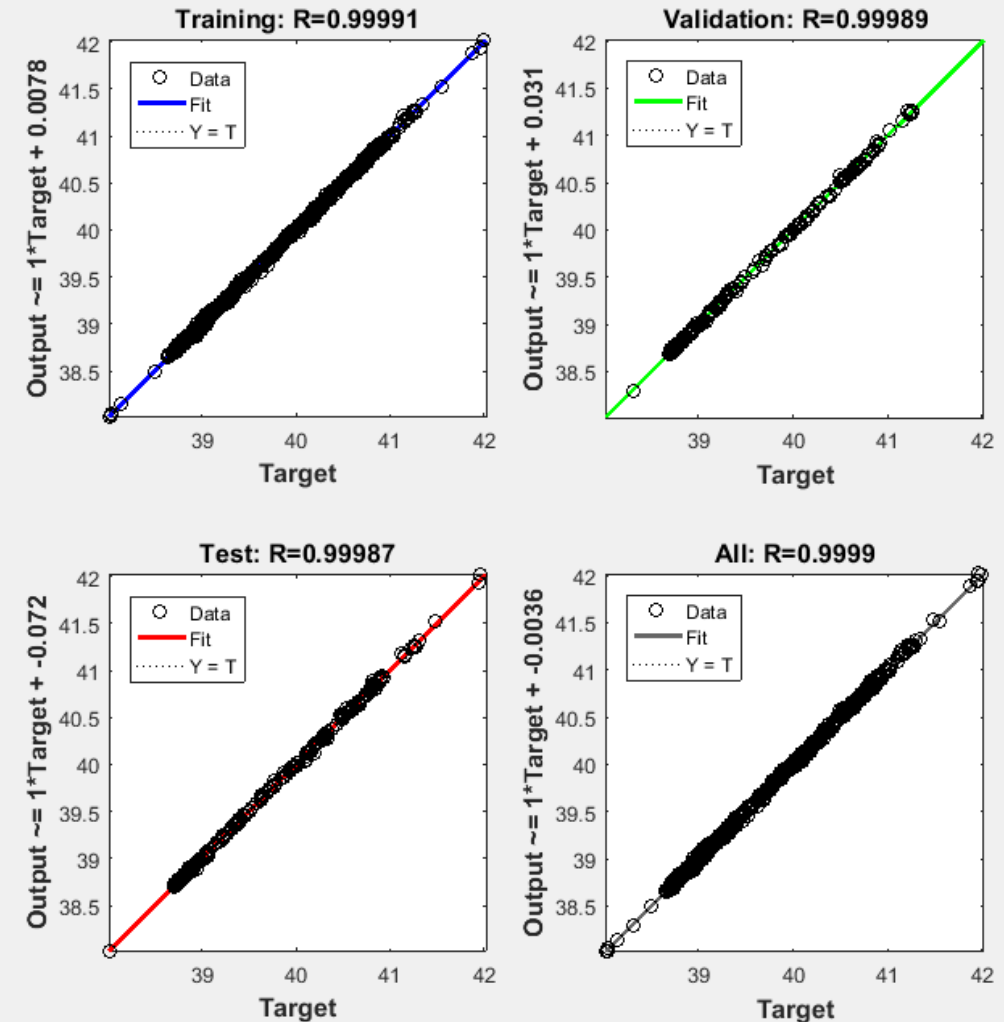


ATUAÇÃO DOS MOTORES



CONTROLE DE DRONES







- Medidas de qualidade:
- Erro Quadrático Médio
 - Boa medida para a situação, descreve desvio da trajetória da atuação dos motores ao longo do tempo
- Resposta ao Degrau
 - Medida de qualidade do método de controle usado
- Índice de correlação de Pearson
 - Indica correlação entre resultados obtidos e resultados esperados



CONTROLE DE DRONES

- Medidas de qualidade:
- Erro Quadrático Médio
 - Boa medida para a situação, descreve desvio da trajetória da atuação dos motores ao longo do tempo







$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} = \sqrt{\frac{x_1^2 + x_2^2 + \dots + x_n^2}{n}}$$

	 Samples	 MSE	 R
 Training:	601	2.96313e-4	9.99985e-1
 Validation:	129	1.67706e-4	9.99987e-1
 Testing:	129	2.93179e-4	9.99971e-1

CONTROLE DE DRONES



- Erro Quadrático Médio – Resultado
- Considerando que os dados de saída são uma porcentagem, 0% - 100%, com amplitude de ~20% nesta simulação o erro quadrático médio obtido está numa ordem de grandeza significativamente menor que a dos dados de saída.

$$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} = \sqrt{\frac{x_1^2 + x_2^2 + \dots + x_n^2}{n}}$$

	 Samples	 MSE	 R
 Training:	601	2.96313e-4	9.99985e-1
 Validation:	129	1.67706e-4	9.99987e-1
 Testing:	129	2.93179e-4	9.99971e-1





CONTROLE DE DRONES

- Resposta ao Degrau
 - Medida de qualidade do método de controle usado
- O sistema é submetido a condições esperadas (alvos) em formato de degrau. Sua resposta é analisada e várias características do sistema podem ser interpretadas dos resultados







CONTROLE DE DRONES

- Índice de correlação de Pearson
 - Indica correlação entre resultados obtidos e resultados esperados
 - Medida feita com todos os conjuntos de dados (treino, teste, validação e a união de todos os conjuntos)
 - Valor R indica o quão linear é a correlação entre as respostas obtidas pela rede neural quando comparadas com as respostas esperadas para cada valor de entrada específico
 - Varia de -1 a 1, valores próximos de 1 indicam forte correlação linear, valores próximos de 0 indicam nenhuma correlação linear



CONTROLE DE DRONES

- Índice de correlação de Pearson – Resultados
 - Foi obtido um índice extremamente próximo de 1, indicando a proximidade dos dados resultantes com os obtidos




CONTROLE DE DRONES

■ Resposta ao Degrau


São analisados os seguintes dados:

- Settling time: tempo até o sistema estar dentro de uma tolerância (2%) em relação ao alvo
- Settling Minimum e Maximum: Erros máximos obtidos na estabilização do sistema uma vez que a resposta atinge o alvo
- Overshoot e Undershoot são erros relativos em relação ao alvo
- Peak – Máximo valor absoluto da diferença entre resposta e alvo
- PeakTime – Instante de tempo no qual pico ocorre




CONTROLE DE DRONES

- Simulação consiste em um degrau de alvo 0m - > 10m aplicado no instante de tempo $t_0 = 10$ s. Valores dos resultados estão em função destas entradas
- Na simulação concorrente, com o controle PID controlando o sistema e a rede neural prevendo seu passo seguinte há resultados muito próximos




CONTROLE DE DRONES

- Porém, ao deixar a rede neural controlar o sistema sozinha, a propagação do pequeno erro do resultado gera situações não treinadas, já que não correspondem ao comportamento PID que foi usado no treinamento da rede.
- Ao deixar a rede controlando o sistema sozinho, o drone não atinge o objetivo




CONTROLE DE DRONES


- Para otimização do resultado foi utilizada escolha e teste de 3 topologias de rede neural diferentes (12 – 12 – 4, 12 – 15 – 4, 12 – 5 – 4), além da utilização de Principal Component Analysis (PCA).
- Resultados foram similares, com a peculiaridade de treino da rede neural foi executado em menos epochs quando PCA foi utilizado (44 vs 101)



CONTROLE DE DRONES



Sem PCA



Com PCA

CONTROLE DE DRONES

Performance

- Utilizando uma função gerada que representa a rede neural treinada, utilizaram-se todos os dados (859) de entrada de uma simulação e foram gastos 0.188132 segundos para o cálculo de atuação resultante para 45 segundos de simulação.
- Nota-se que cada tick da simulação (intervalo de tempo no qual os estados são atualizados) ocorrem a cada 0.001 segundo; foram gerados 859 dados em 0.188132 segundos, ou seja, um dado a cada ~ 0.000219 segundos, mais do que suficiente para acompanhar a taxa da simulação.
- Além disso, a simulação demora 15.023989 segundos para ser concluída

```
Elapsed time is 15.023989 seconds.
```

```
>> tic, myNeuralNetworkFunction(PC_patamar_znulo_rec_entradas), toc  
Elapsed time is 0.188132 seconds.
```