

Modelagem e Otimização de Consumo Energético de Smartphones Android Baseado em Perfis de Uso

Antônio Sá Barreto <acsbn@cin.ufpe.br>

Orientador: Prof. Dr. Paulo Maciel

Co-orientador: Prof. Dr. Germano Crispim Vasconcelos



Agenda

1. Justificativa
2. Objetivos
3. Primeira tentativa
4. Segunda Tentativa
5. Terceira Tentativa
6. Direções Futuras



1. Justificativa

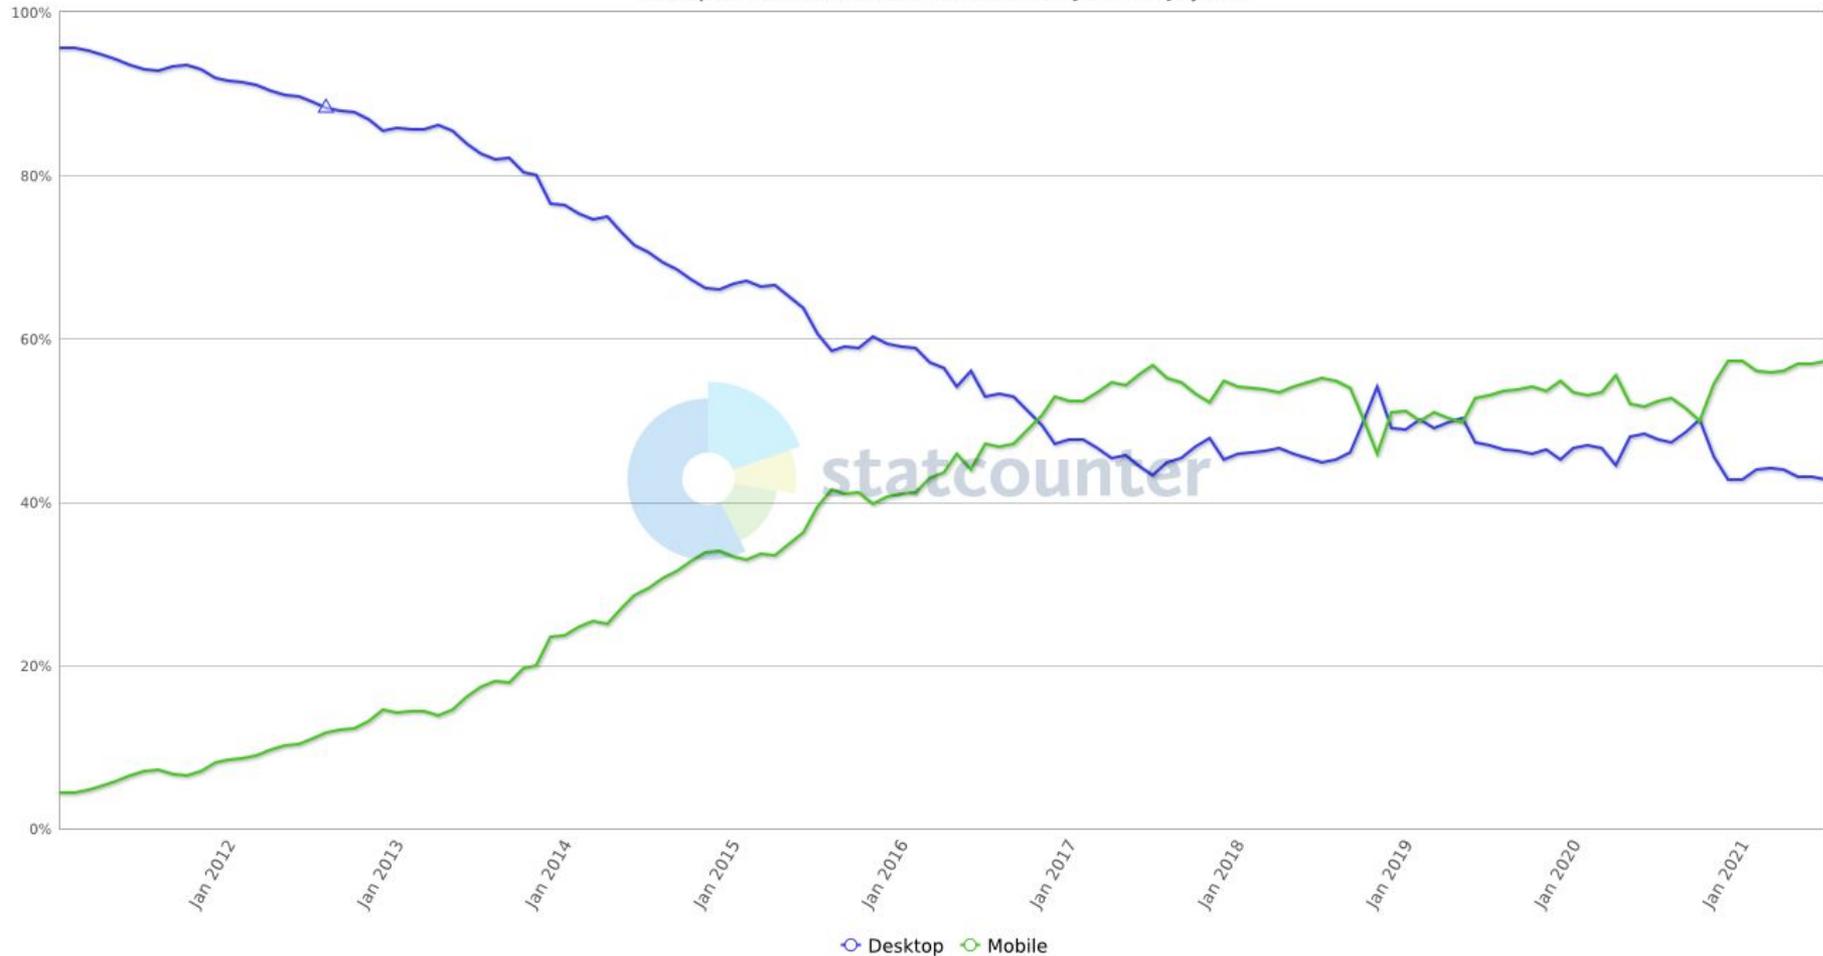
- O uso de smartphones tem conquistado cada dia mais espaço no mercado
- De acordo com Smart Insights(2017) a utilização de smartphones ultrapassou o uso de computadores desktop em 2014, chegando a marca de 1,8 milhões
- Conforme a Smart Insights (2017), o uso da Internet por meio de dispositivos móveis chegou à marca de 51% do total de acessos



1. Justificativa

Em Junho de 2021, a StatCounter (2021) publicou um estudo segundo o qual o uso dos dispositivos móveis ultrapassou o uso de computadores desktop, passando a responder por uma fatia de mercado correspondente a 56.9% vs. 43.1%.

StatCounter Global Stats
Desktop vs Mobile Market Share Worldwide from Jan 2011 - July 2021





1. Justificativa

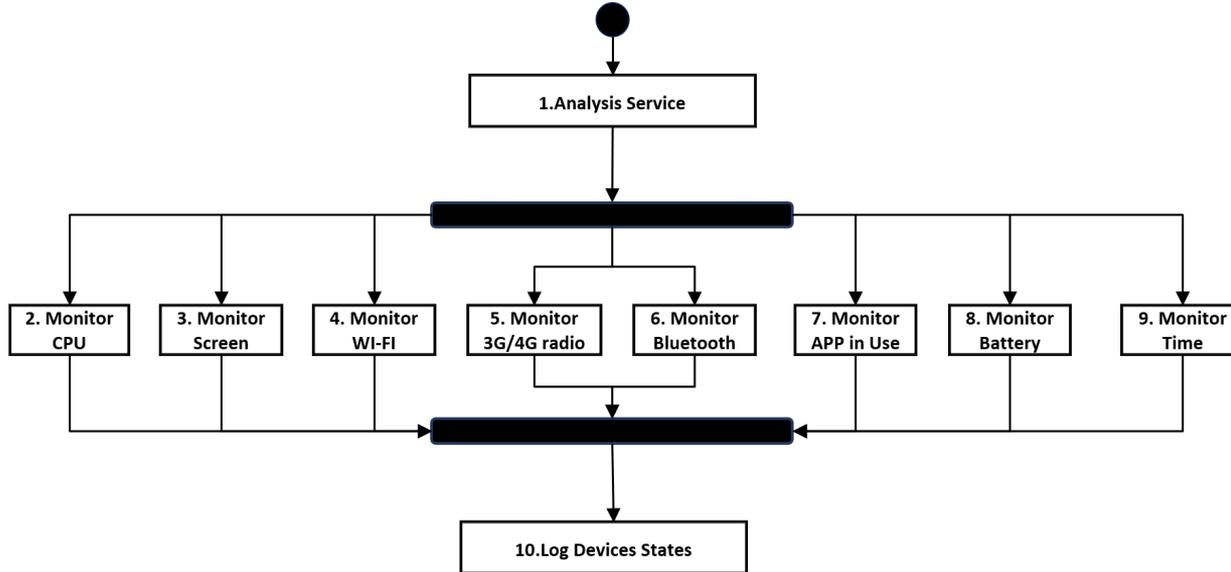
Em 2018 o Android Authority avaliou se a capacidade das baterias realmente evoluíram. Eles concluíram que, em 5 anos, a capacidade das baterias evoluíram de 3300mAh para 3500mAh e estimaram que em 2020 as baterias com 4000mAh seriam comuns, o que foi confirmado pelo uso desse tipo de bateria em smartphones como o Samsung Galaxy S20 e Samsung Galaxy S21.



2. Objetivos

Criar uma estratégia adaptativa baseada no perfil de uso do usuário para descobrir boas configurações dos dispositivos do smartphone que visem à redução do consumo energético.

3. Primeira Tentativa-Modelagem com DTMC





3. Primeira Tentativa-Modelagem com DTMC

State

(CPU Freq, Screen State, WI-FI State, Radio State, Bluetooth State, App in Use, Battery Charge, Time)

From State

To State

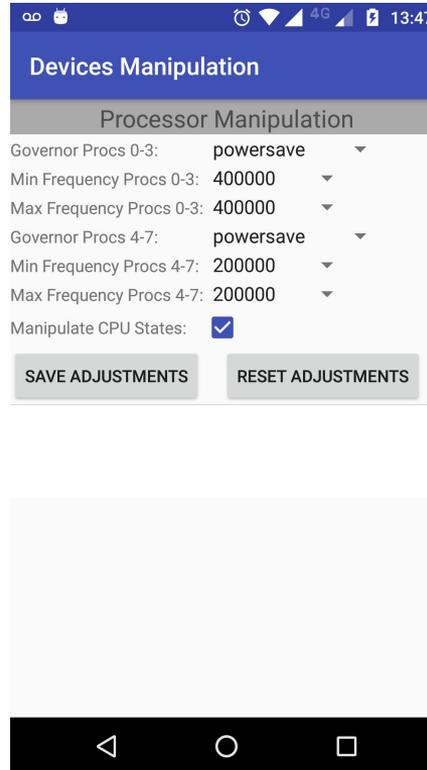


3. Primeira Tentativa-Modelagem com DTMC

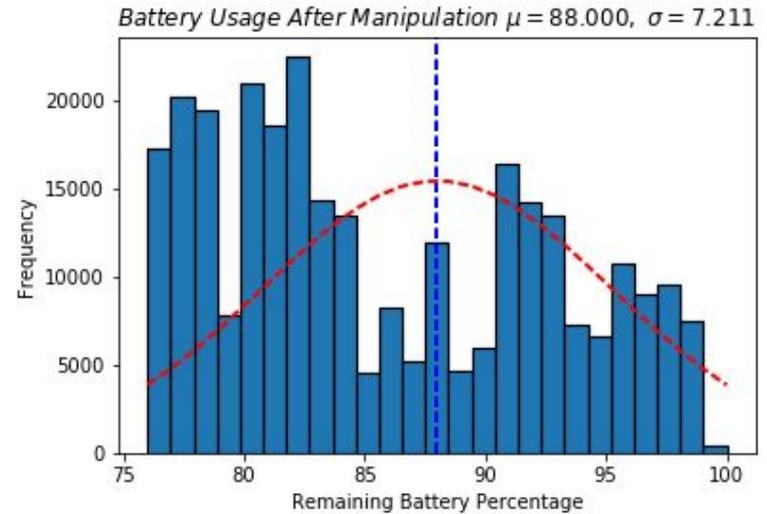
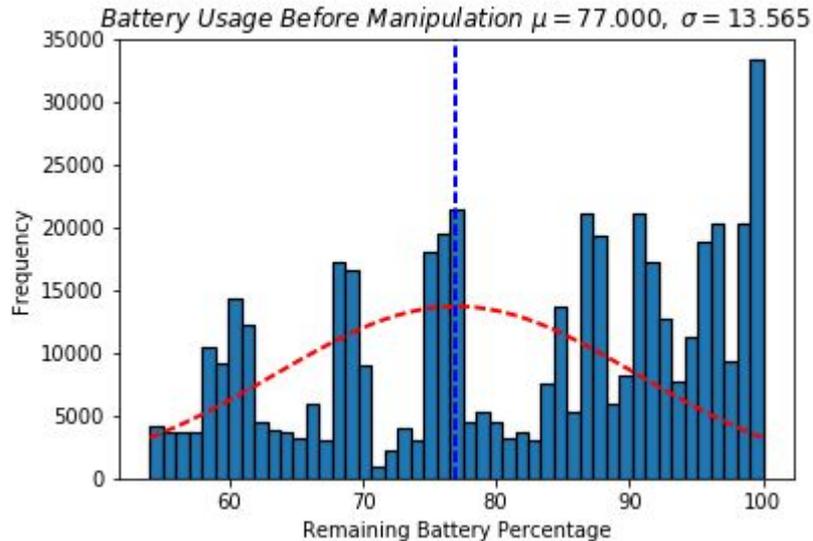
CPU 1	CPU 2	Screen	Wi-Fi	3G/4G radio	BT	Prob.
400000	200000	OFF	ACTIVE	NOT CONN	OFF	0.964
1459200	800000	ON	ACTIVE	NOT CONN	OFF	0.024
1651200	800000	ON	ACTIVE	NOT CONN	OFF	0.003
1459200	998400	ON	ACTIVE	NOT CONN	OFF	0.003
1651200	998400	ON	ACTIVE	NOT CONN	OFF	0.001



3. Primeira Tentativa-Modelagem com DTMC



3. Primeira Tentativa-Modelagem com DTMC

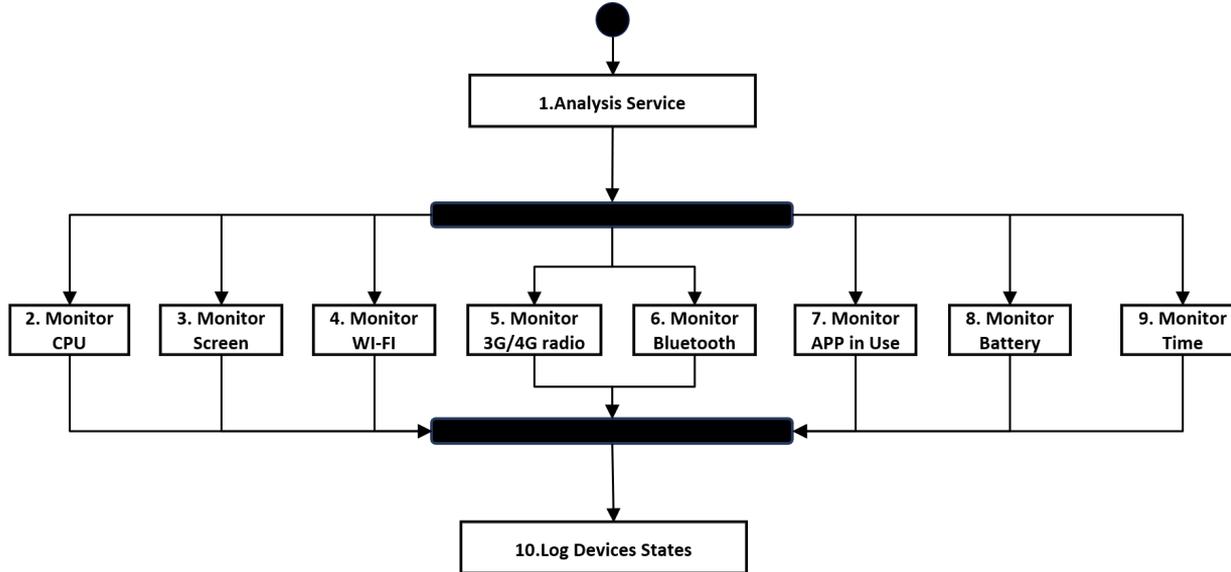




4. Segunda Tentativa- Agora Vai

- Não podemos buscar reduzir o consumo energético se não temos uma forma de associar o comportamento do usuário com o consumo do smartphone
- Resultado: precisamos desenvolver um modelo regressor capaz de associar o comportamento do usuário ao consumo do smartphone

4. Segunda Tentativa- Agora Vai





4. Segunda Tentativa-Modelagem de Consumo

- Usar o Battery Manager do Android
- Primeiros resultados

Média de Potência da Amostra: 339.2154585 mw



Configuração	Média do Erro Absoluto	Desvio padrão do erro absoluto
Função Linear na saída-1 camada escondida	152.3396529	55.11082535
Função Sigmoid, dados escalados - 1 camada escondida	253.3357268	159.3279256
Função Sigmoid, dados escalados - 3 camadas escondidas e 2 camadas Dropout	297.8355557	172.4317974
Função Sigmoid, dados escalados - 2 camadas escondidas e 2 camadas Dropout	283.3026375	164.7588971
Função Sigmoid, dados escalados - 1 camadas escondidas e 1 camadas Dropout	233.0254992	125.7908027



5. Terceira Tentativa- Agora precisa dar certo

- Usar O Battery Manager do Android
- Criação de novas Features- Em Média 29 novas Features
 - Brilho
 - Temp. CPU
 - Intensidade de Sinal Mobile
 - Intensidade de Sinal WiFi
 - Kb Read
 - Kb Write
 - Context Switch
 - Mean and Std of Pixel Colors (OpenCV for Android)
 - ...



5. Terceira Tentativa- Agora precisa dar certo

- **Novos Resultados**

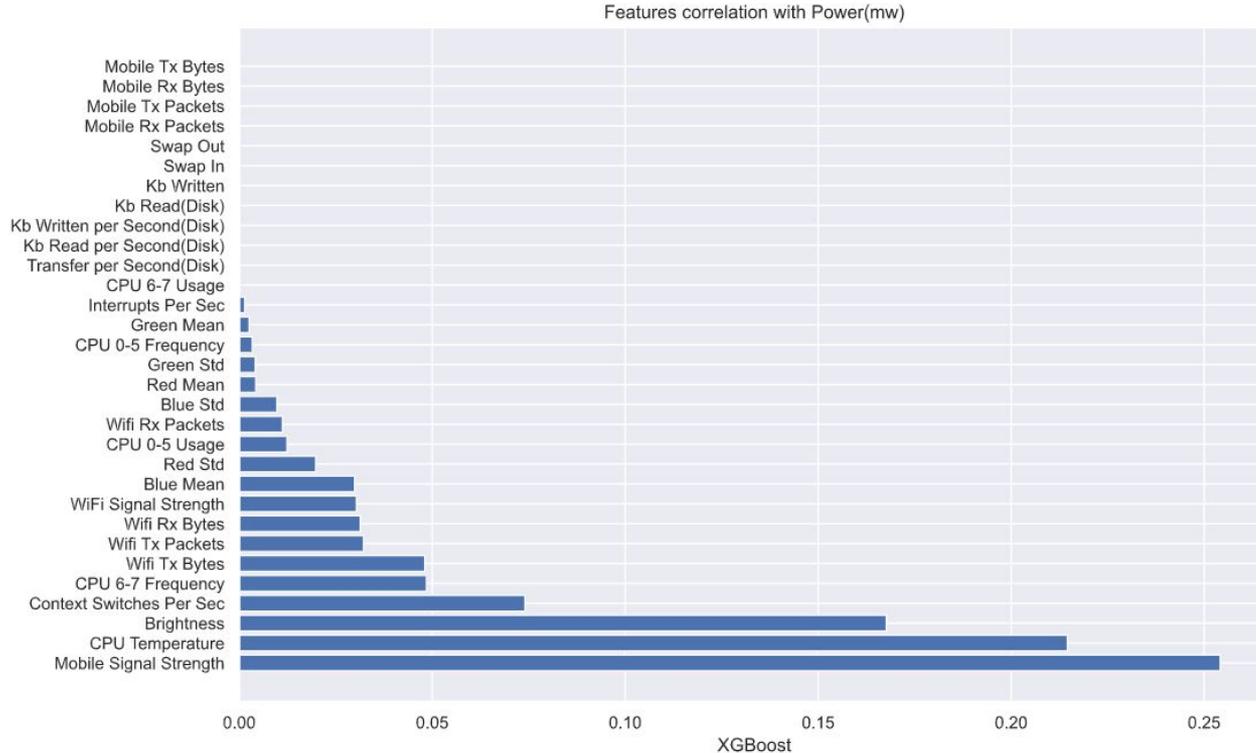
Média de Potência da Amostra: 1971.410039 mW



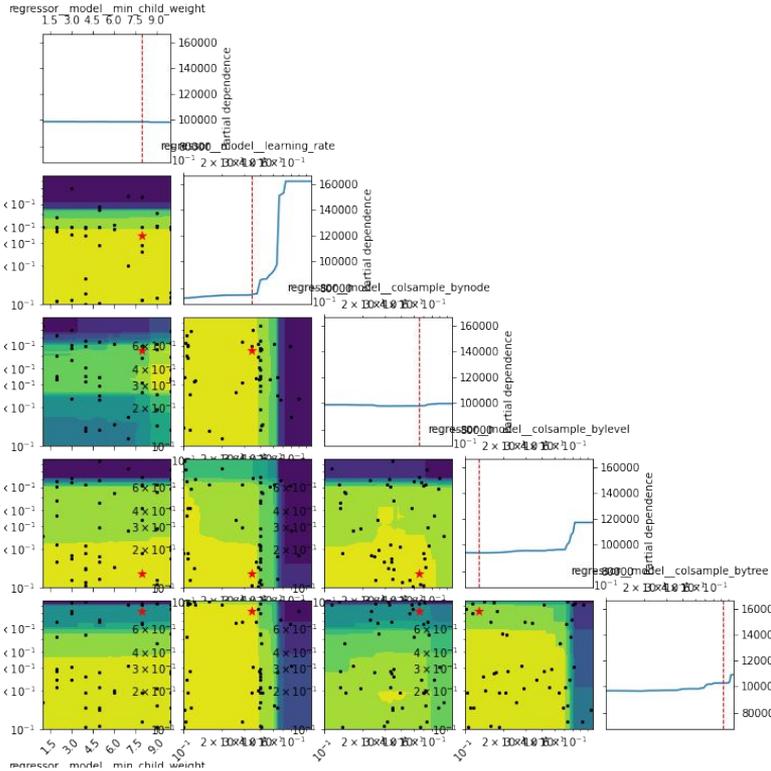
Configuração	Média do Erro Absoluto	Desvio padrão do erro absoluto
Gradient Boosting Regressor	258.1009	0
SVR	280.9656	0
MLP	1893.7354	7687.805335
LSTM	578.8738	157.4232



5. Terceira Tentativa-Features Importance



5. Terceira Tentativa-Otimização de Hiperparâmetros





5. Terceira Tentativa- Considerações Importantes

- Utilização de validação cruzada
- Utilização de técnica proposta por Andrew Ng(1997). para evitar overfitting no conjunto de validação
- Remoção de outliers durante a fase de preparação dos dados
- Utilização de técnicas de otimização Greedy e Global para seleção de atributos, conforme discutido por Kuhn e Johnson(2019).
- Utilização de técnicas de MLOPS para controle dos experimentos e salvamento de modelos
- Integração de modelos de Machine Learning e Redes Neurais de modo a automatizar a criação e comparação de modelos

5. Terceira tentativa- Resultados

Table 16: Test data set prediction error for instant power(mW)

Smartphone	Scenario	Algorithm	Mean Absolute Error(MAE)
Galaxy A10	All Features	XGB	288.526
	All Features GAFS	XGB	647.487
	All Features RFEFS	LSTM	256.166
	Only Numerical	Random Forest	257.841
	Only Numerical GAFS	LSTM	358.911
	Only Numerical RFEFS	XGB	410.233
Moto G6	All Features	LSTM	108.476
	All Features GAFS	LSTM	1857.7991
	All Features RFEFS	LSTM	212.027
	Only Numerical	LSTM	356.099
	Only Numerical GAFS	LSTM	112.952
	Only Numerical RFEFS	LSTM	223.602



5. Terceira tentativa- Resultados

- **Artigo Publicado: NETO, Antônio Sá Barreto et al. Building energy consumption models based on smartphone user's usage patterns. Knowledge-Based Systems, v. 213, p. 106680, 2021.**
- **Artigo no forno: Building Devices' Usage Models Based on Smartphone User's Usage Patterns**



6. Direções Futuras

- Avaliar situações de Drift de Dados e online learning
- Utilizar algoritmos de otimização utilizados para otimizar hiperparâmetros para achar configurações dos dispositivos do smartphone que visem à redução do consumo energético.



Obrigado

Antônio Sá Barreto <acsbn@cin.ufpe.br>

Orientador: Paulo R. M. Maciel

<prmm@cin.ufpe.br>

Recife/2019