Aprendizado de Máquina Aplicado a Localização de Usuários em Redes sem Fio: Oportunidades e Desafios

Larissa Oliveira
Gustavo Bittencourt
Lizandro Silva
Robson Timoteo
Daniel Cunha
Felipe S. Andrade

Sumário

1 Apresentação

2 Objetivos

3 Introdução

4 Revisitando técnicas e tecnologias de localização

5 Conceitos básicos aprendizado de máquina

6 Aprendizado de Máquina aplicado às técnicas de localização

7 Oportunidades e desafios

Apresentação

Apresentação

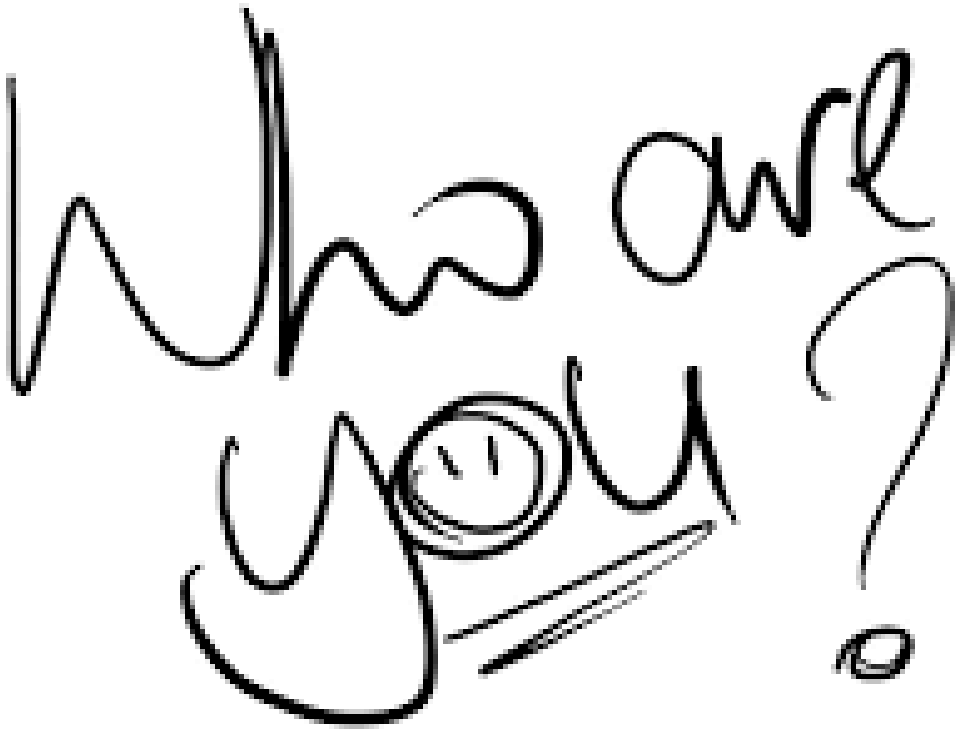

O que vamos aprender?

O que vamos aprender?

- As principais técnicas e algoritmos voltados à localização de dispositivos móveis;

O que vamos aprender?

- As principais técnicas e algoritmos voltados à localização de dispositivos móveis;
- Os conceitos básicos de aprendizado de máquina;

O que vamos aprender?

- As principais técnicas e algoritmos voltados à localização de dispositivos móveis;
- Os conceitos básicos de aprendizado de máquina;
- Aplicação do aprendizado de máquina para resolver problemas de localização;

O que vamos aprender?

- As principais técnicas e algoritmos voltados à localização de dispositivos móveis;
- Os conceitos básicos de aprendizado de máquina;
- Aplicação do aprendizado de máquina para resolver problemas de localização;
- Visualizar oportunidades e desafios para aplicação no campo da localização de dispositivos em redes sem fio.

Introdução

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

OUTDOOR OU INDOOR?

GPS ou redes sem fio?

Qual o ambiente mais adequado para aplicar os diversos tipos de tecnologias de localização?

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

OUTDOOR OU INDOOR?

GPS ou redes sem fio?

Qual o ambiente mais adequado para aplicar os diversos tipos de tecnologias de localização?

ACURÁCIA OU PRECISÃO?

Às vezes confunde

Conceitos muito próximos, mas há diferenças entre eles.

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

MODELOS DE PROPAGAÇÃO

Quais as dificuldades?

Tais técnicas tendem a ser impactadas por efeitos colaterais indesejados como a presença de ruído, dispersão e sombreamento.

OUTDOOR OU INDOOR?

GPS ou redes sem fio?

Qual o ambiente mais adequado para aplicar os diversos tipos de tecnologias de localização?

ACURÁCIA OU PRECISÃO?

Às vezes confunde

Conceitos muito próximos, mas há diferenças entre eles.

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

OUTDOOR OU INDOOR?

GPS ou redes sem fio?

Qual o ambiente mais adequado para aplicar os diversos tipos de tecnologias de localização?

ACURÁCIA OU PRECISÃO?

Às vezes confunde

Conceitos muito próximos, mas há diferenças entre eles.

MODELOS DE PROPAGAÇÃO

Quais as dificuldades?

Tais técnicas tendem a ser impactadas por efeitos colaterais indesejados como a presença de ruído, dispersão e sombreamento.

APRENDIZADO DE MÁQUINA

Conhecendo um pouco mais

Uma solução para resolver a complexidade natural em modelar sistemas não lineares.

Introdução

CIDADES INTELIGENTES

Como ser modernas e sustentáveis?

Tecnologias de localização, fundamentais para o desenvolvimento do conceito de cidades inteligentes.

OUTDOOR OU INDOOR?

GPS ou redes sem fio?

Qual o ambiente mais adequado para aplicar os diversos tipos de tecnologias de localização?

ACURÁCIA OU PRECISÃO?

Às vezes confunde

Conceitos muito próximos, mas há diferenças entre eles.

MODELOS DE PROPAGAÇÃO

Quais as dificuldades?

Tais técnicas tendem a ser impactadas por efeitos colaterais indesejados como a presença de ruído, dispersão e sombreamento.

APRENDIZADO DE MÁQUINA

Conhecendo um pouco mais

Uma solução para resolver a complexidade natural em modelar sistemas não lineares.

APLICAÇÕES, DESAFIOS E OPORTUNIDADES

Direções de pesquisa

Existem formas de aplicar o aprendizado de máquina para localizar dispositivos móveis.

Sumário

1 Apresentação

2 Objetivos

3 Introdução

4 Revisitando técnicas e tecnologias de localização

5 Conceitos básicos aprendizado de máquina

6 Aprendizado de Máquina aplicado às técnicas de localização

7 Oportunidades e desafios

Antes de começar:

Antes de começar:

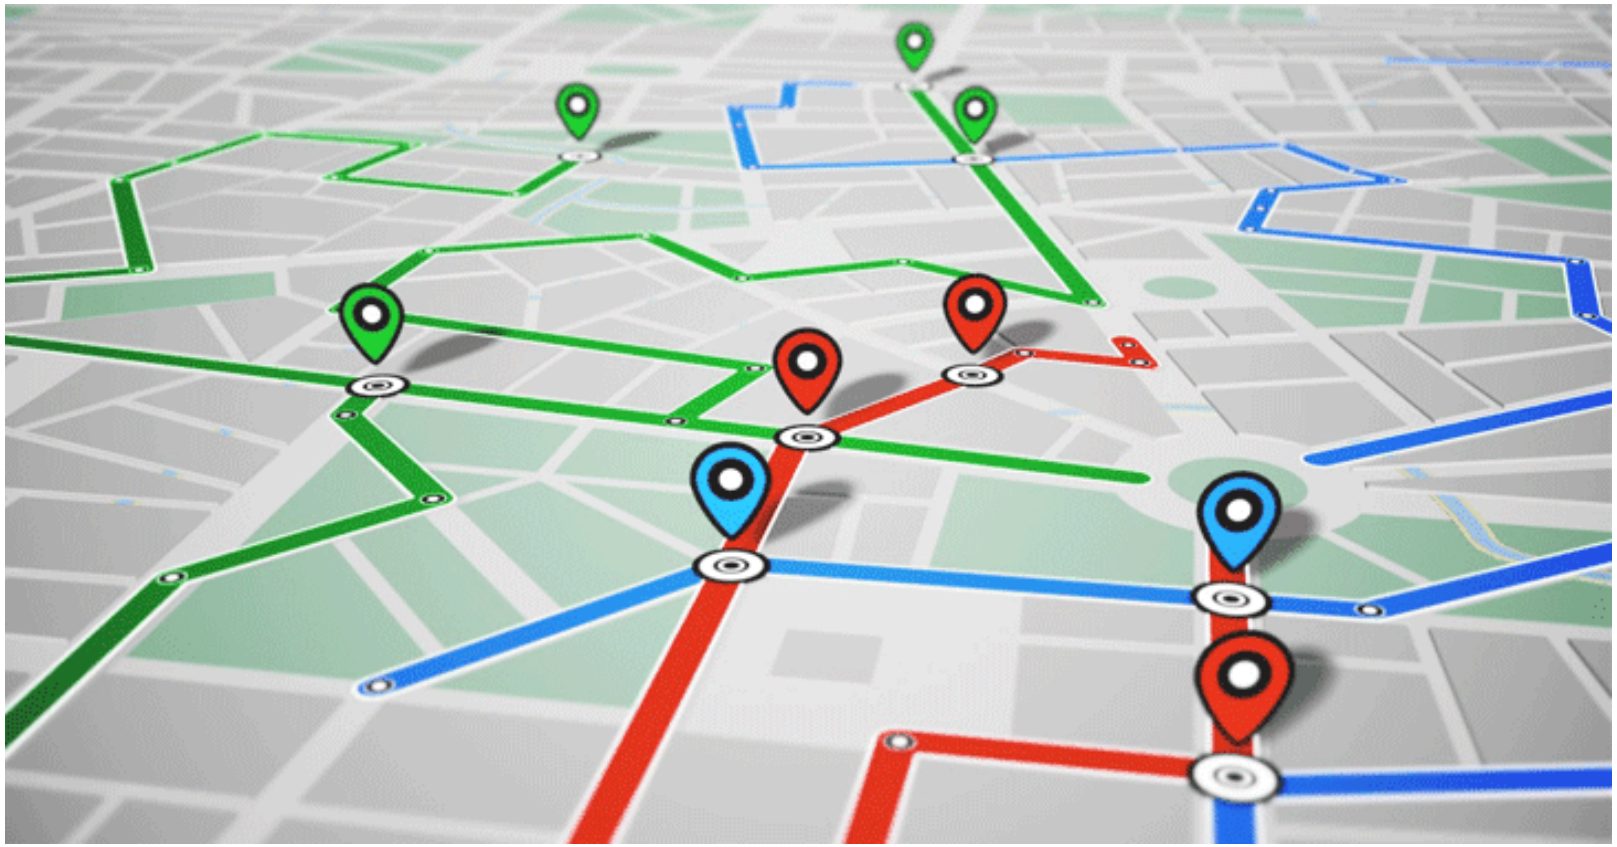

Posição, localização ou navegação?

Antes de começar:

Antes de começar:

Acurácia x Precisão?

Como localizar dispositivos numa rede sem fio?

Como localizar dispositivos numa rede sem fio?

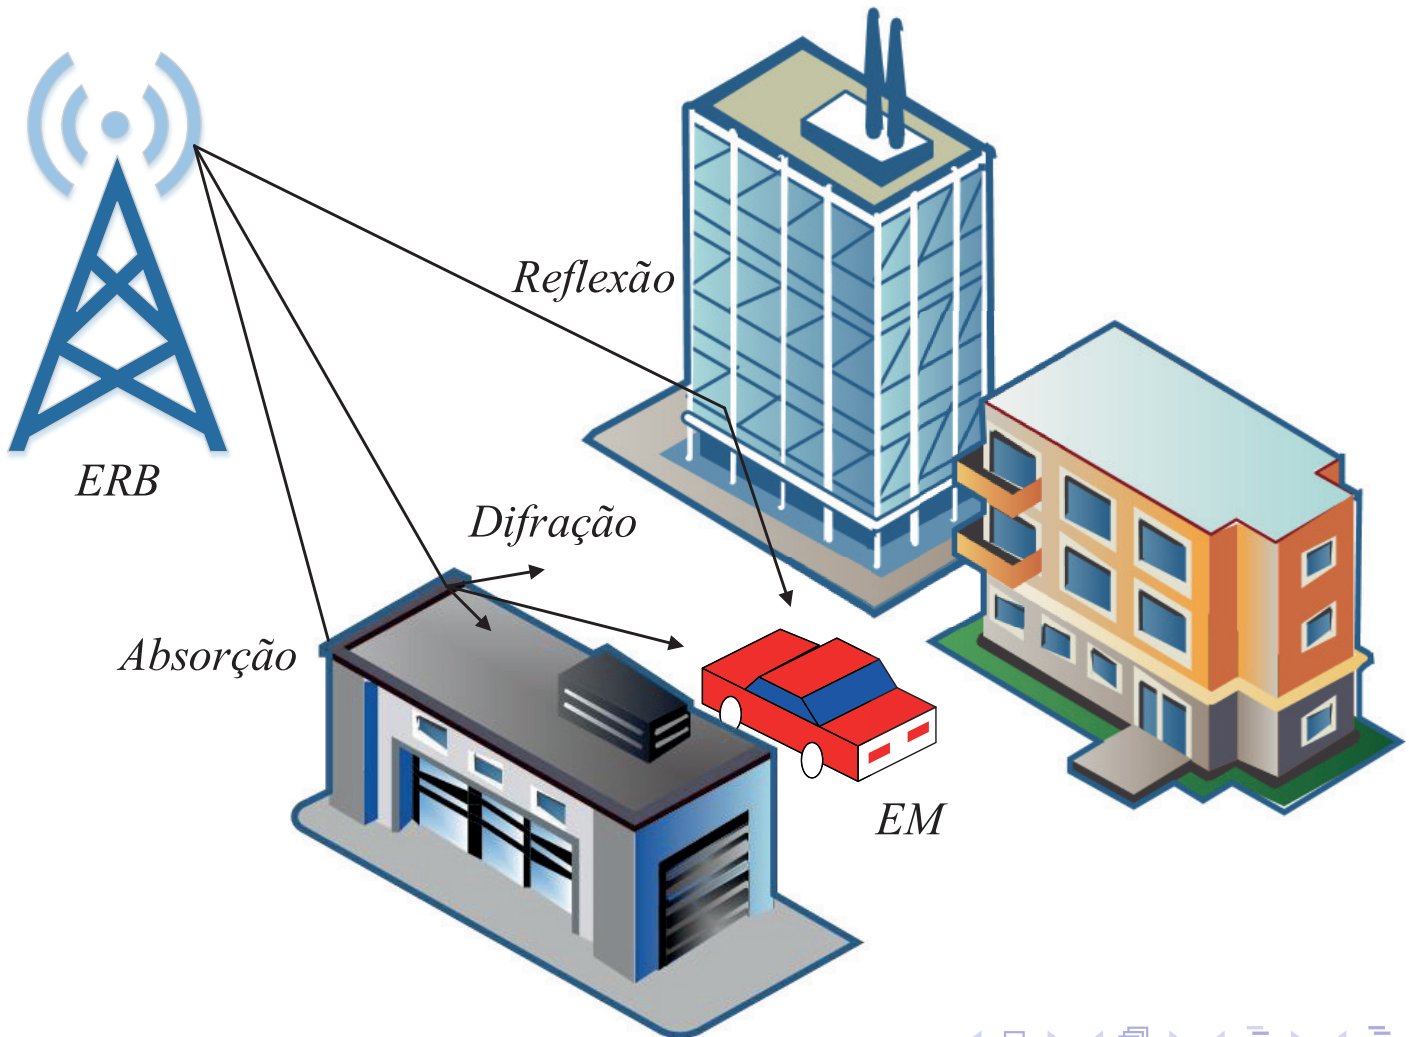

Como localizar dispositivos numa rede sem fio?

Como localizar dispositivos numa rede sem fio?

1. Parâmetros dos sinais de radiofrequência (RF);
2. Classificação de técnicas de localização;
3. Técnicas mais difundidas na literatura.

Parâmetros de RF

Parâmetros de RF

- ToA: *Time of arrival*;

Parâmetros de RF

- ToA: *Time of arrival*;
- TDoA: *Time difference of arrival*;

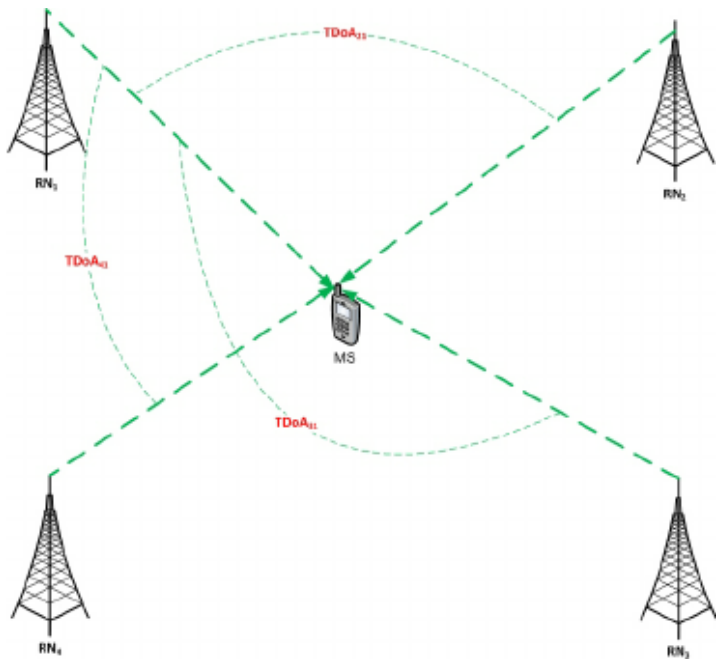

Parâmetros de RF

Parâmetros de RF

- AoA: *Angle of arrival*;

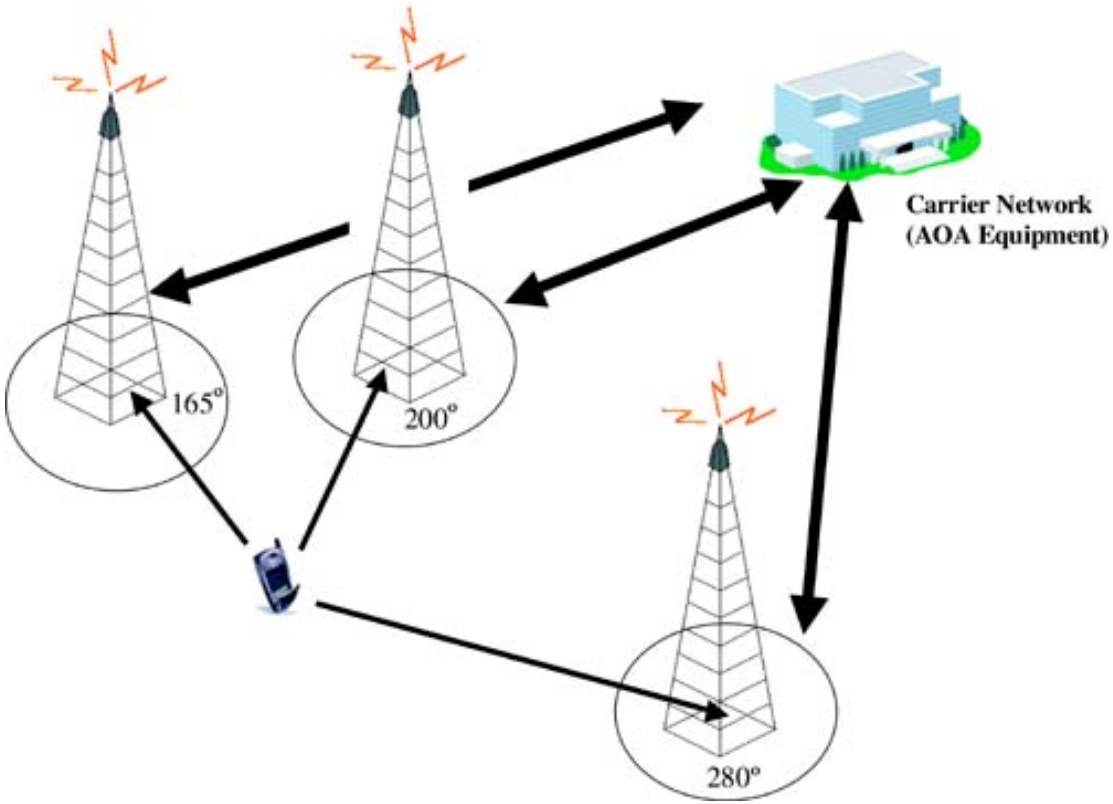

Parâmetros de RF

Parâmetros de RF

- RSSI: *Received signal strength indicator*.

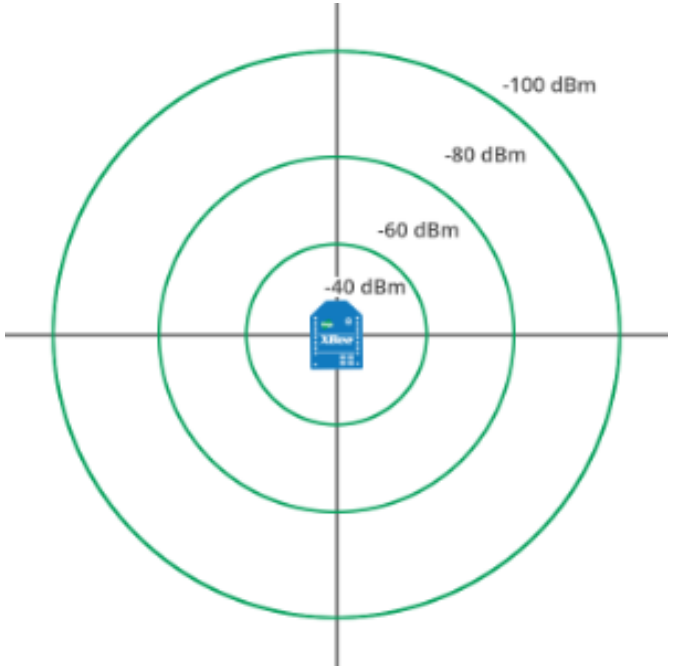

Classificação de sistemas de localização de redes sem fio

Classificação de sistemas de localização de redes sem fio

- **Por topologia:** Quando se refere ao equipamento onde os níveis de sinais são medidos e/ou processados;

Classificação de sistemas de localização de redes sem fio

- **Por topologia:** Quando se refere ao equipamento onde os níveis de sinais são medidos e/ou processados;
- **Por cobertura:** Quando se refere a abrangência da cobertura fornecida pela rede sem fio.

Classificação de sistemas de localização por topologia

Classificação de sistemas de localização por topologia

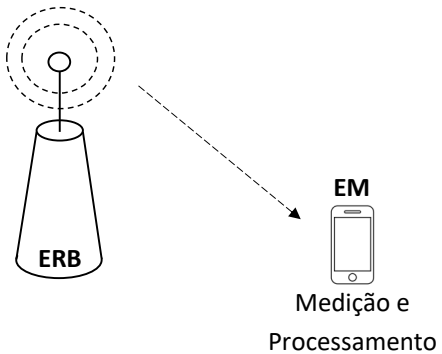

(a) Auto-localização.

Classificação de sistemas de localização por topologia

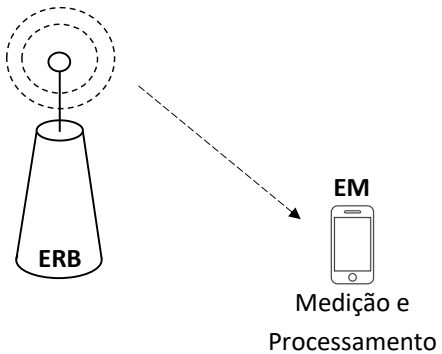

(a) Auto-localização.

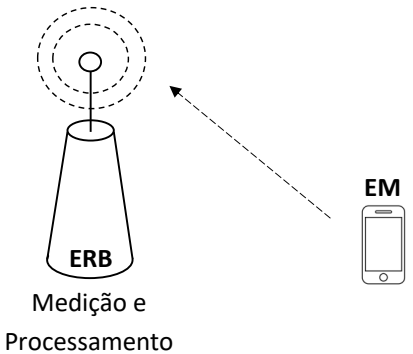

(b) Localização remota.

Classificação de sistemas de localização por topologia

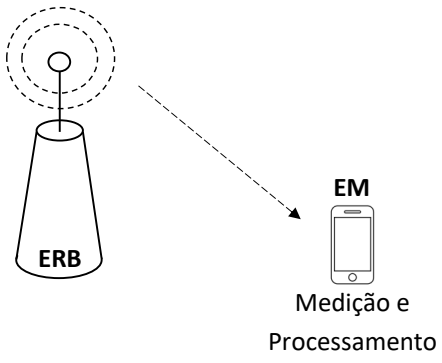

(a) Auto-localização.

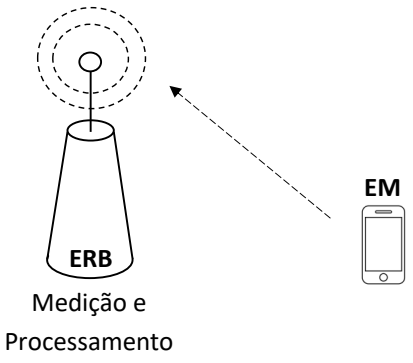

(b) Localização remota.

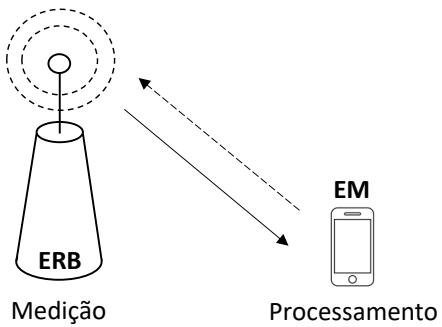

(c) Auto-localização indireta.

Classificação de sistemas de localização por topologia

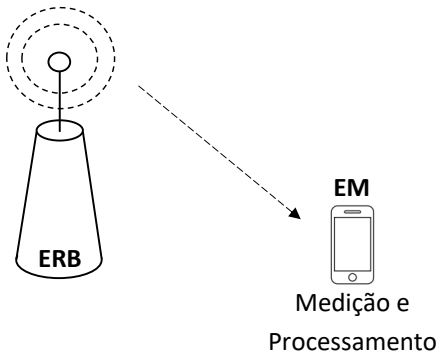

(a) Auto-localização.

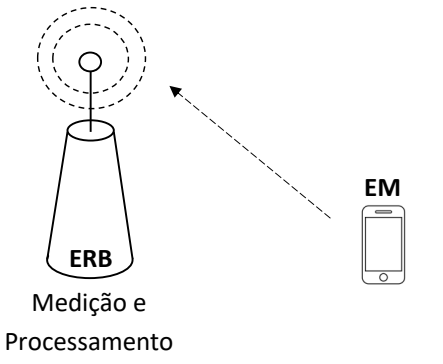

(b) Localização remota.

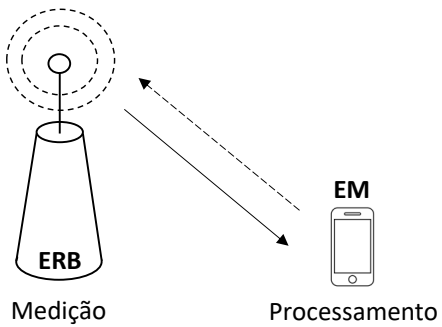

(c) Auto-localização indireta.

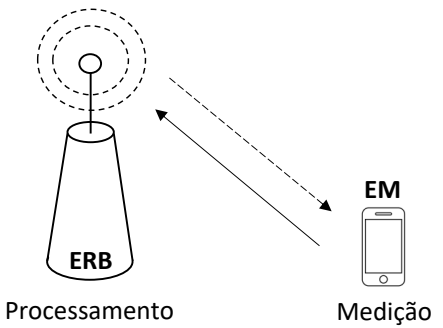

(d) Loc. remota indireta.

Figura: Topologia de sistemas de localização.

Classificação de sistemas de localização por cobertura

Classificação de sistemas de localização por cobertura

- **Satélite:**
  - Tecnologia: GPS (*Global positioning system*);
  - Ambiente: *Outdoor*;
  - Acurácia: 3 *m*.

Classificação de sistemas de localização por cobertura

- **Telefonia Celular:**
  - Tecnologia: 1G a 5G;
  - Ambiente: *Outdoor*;
  - Acurácia: 50 *m*.

Classificação de sistemas de localização por cobertura

- **Pequena cobertura:**
  - Tecnologia: WLAN;
  - Ambiente: *Indoor*;
  - Acurácia: 5 *m*.

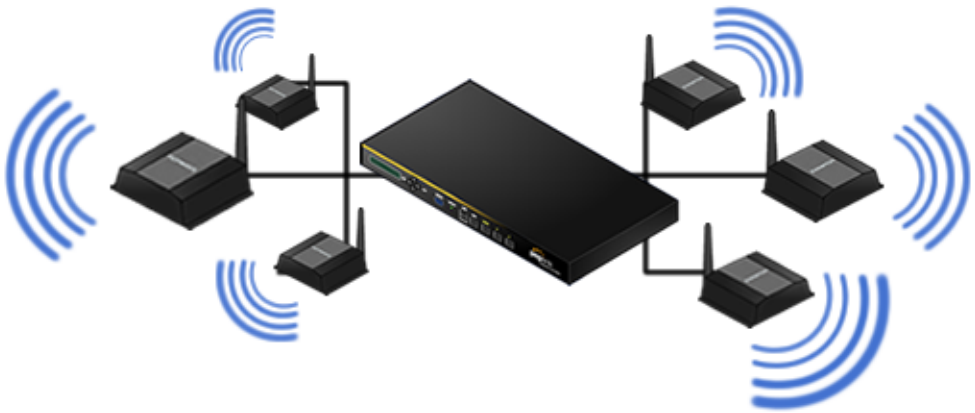

Técnicas básicas de localização

Técnicas básicas de localização

- **Lateração**: A determinação da localização de um ponto (EM, no caso) por meio de argumentos geométricos;

Técnicas básicas de localização

- **Lateração**: A determinação da localização de um ponto (EM, no caso) por meio de argumentos geométricos;
- ***Fingerprinting***: Grupo de métodos para a localização de usuários móveis, bastante adequado para ambientes sem visada direta (NLoS) e que podem ser aplicados em qualquer modalidade de rede sem fio.

Técnicas básicas de localização: **Trilateração**

Técnicas básicas de localização: **Trilateração**

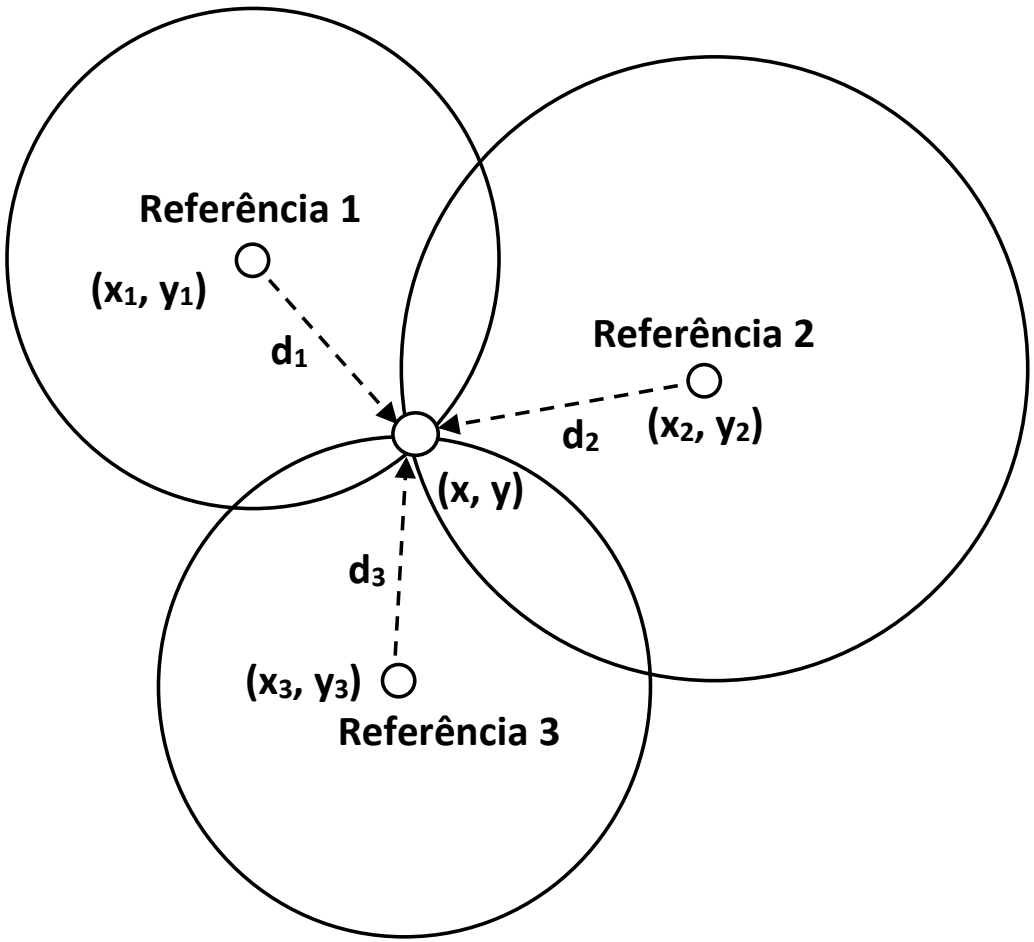

Figura: Representação gráfica do caso ideal da trilateração de potência.

Técnicas básicas de localização: **Trilateração**

Técnicas básicas de localização: **Trilateração**

$$\begin{cases} (x_p - x_1)^2 + (y_p - y_1)^2 &= d_1^2 \\ (x_p - x_2)^2 + (y_p - y_2)^2 &= d_2^2 \\ (x_p - x_3)^2 + (y_p - y_3)^2 &= d_3^2 \end{cases},$$

Técnicas básicas de localização: **Trilateração**

$$\begin{cases} (x_p - x_1)^2 + (y_p - y_1)^2 &= d_1^2 \\ (x_p - x_2)^2 + (y_p - y_2)^2 &= d_2^2 \\ (x_p - x_3)^2 + (y_p - y_3)^2 &= d_3^2 \end{cases},$$

$$\begin{cases} R \arccos\left[\text{sen}\theta_1 \text{sen}\theta_p + \cos\theta_1 \cos\theta_p \cos(\phi_p - \phi_1)\right] &= dg_1 \\ R \arccos\left[\text{sen}\theta_2 \text{sen}\theta_p + \cos\theta_2 \cos\theta_p \cos(\phi_p - \phi_2)\right] &= dg_2 \\ R \arccos\left[\text{sen}\theta_3 \text{sen}\theta_p + \cos\theta_3 \cos\theta_p \cos(\phi_p - \phi_3)\right] &= dg_3 \end{cases},$$

Técnicas básicas de localização: **Trilateração**

$$\begin{cases} (x_p - x_1)^2 + (y_p - y_1)^2 &= d_1^2 \\ (x_p - x_2)^2 + (y_p - y_2)^2 &= d_2^2 \\ (x_p - x_3)^2 + (y_p - y_3)^2 &= d_3^2 \end{cases} ,$$

$$\begin{cases} R \arccos\left[\text{sen}\theta_1 \text{sen}\theta_p + \cos\theta_1 \cos\theta_p \cos(\phi_p - \phi_1)\right] &= dg_1 \\ R \arccos\left[\text{sen}\theta_2 \text{sen}\theta_p + \cos\theta_2 \cos\theta_p \cos(\phi_p - \phi_2)\right] &= dg_2 \\ R \arccos\left[\text{sen}\theta_3 \text{sen}\theta_p + \cos\theta_3 \cos\theta_p \cos(\phi_p - \phi_3)\right] &= dg_3 \end{cases} ,$$

$$d_i^* = \sqrt{(x_p^* - x_i)^2. + (y_p^* - y_i)^2}, i = 1, 2, 3 \ .$$

Técnicas básicas de localização: *Fingerprinting*

Técnicas básicas de localização: *Fingerprinting*

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;
- Elementos básicos: O *Fingerprint*, o banco de dados, o servidor de localização, a técnica de redução de espaço de busca e o método de reconhecimento de padrões;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;
- Elementos básicos: O *Fingerprint*, o banco de dados, o servidor de localização, a técnica de redução de espaço de busca e o método de reconhecimento de padrões;
- Vetor de atributos: valores utilizados no método de reconhecimento de padrões é denominado *fingerprint*;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;
- Elementos básicos: O *Fingerprint*, o banco de dados, o servidor de localização, a técnica de redução de espaço de busca e o método de reconhecimento de padrões;
- Vetor de atributos: valores utilizados no método de reconhecimento de padrões é denominado *fingerprint*;
- RSSI e COST-231;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;
- Elementos básicos: O *Fingerprint*, o banco de dados, o servidor de localização, a técnica de redução de espaço de busca e o método de reconhecimento de padrões;
- Vetor de atributos: valores utilizados no método de reconhecimento de padrões é denominado *fingerprint*;
- RSSI e COST-231;
- Como não é viável medir todas as posições os modelos são usados para generalizá-los;

Técnicas básicas de localização: *Fingerprinting*

- Adequado para ambientes sem visada direta;
- Existe uma enorme variedade de técnicas de *fingerprinting*;
- Elementos básicos: O *Fingerprint*, o banco de dados, o servidor de localização, a técnica de redução de espaço de busca e o método de reconhecimento de padrões;
- Vetor de atributos: valores utilizados no método de reconhecimento de padrões é denominado *fingerprint*;
- RSSI e COST-231;
- Como não é viável medir todas as posições os modelos são usados para generalizá-los;
- *Fingerprint* Medido x Armazenado: A ideia chave é encontrar o ponto na base de dados que tenha a maior similaridade ou correlação com o valor medido em campo.

Técnicas básicas de localização: *Fingerprinting*

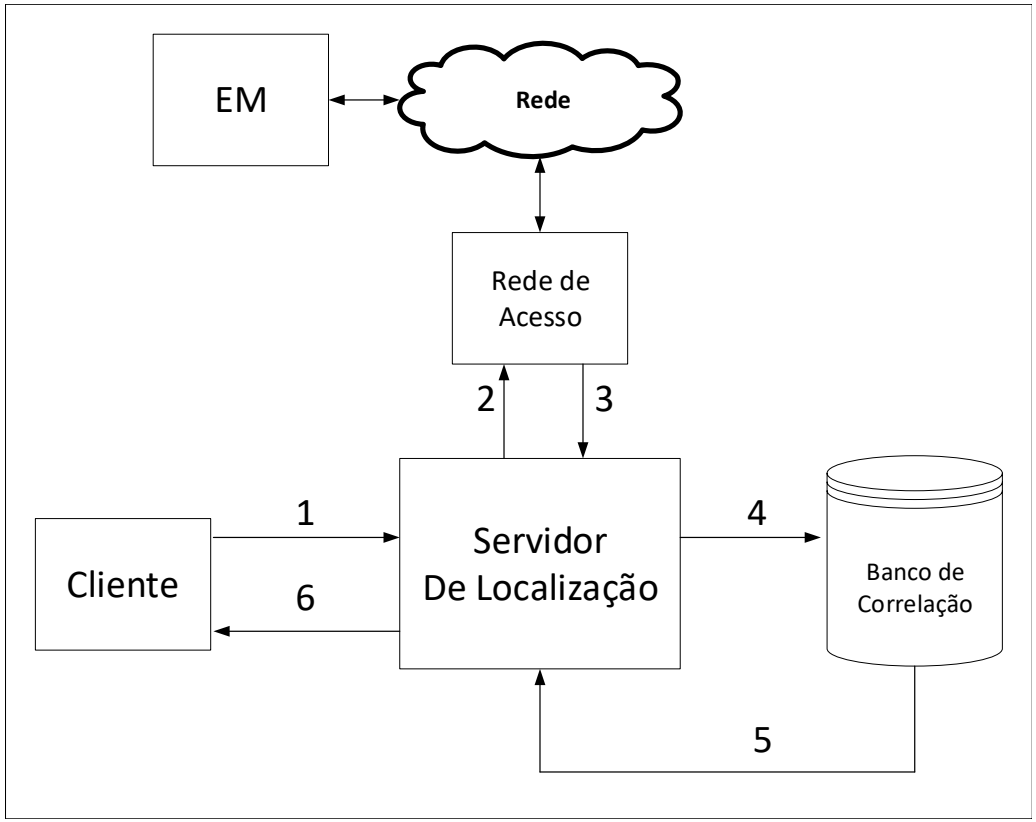

Figura: Diagrama de um sistema baseado em *fingerprinting*.

Sumário

1 Apresentação

2 Objetivos

3 Introdução

4 Revisitando técnicas e tecnologias de localização

5 Conceitos básicos aprendizado de máquina

6 Aprendizado de Máquina aplicado às técnicas de localização

7 Oportunidades e desafios

Introdução

Introdução

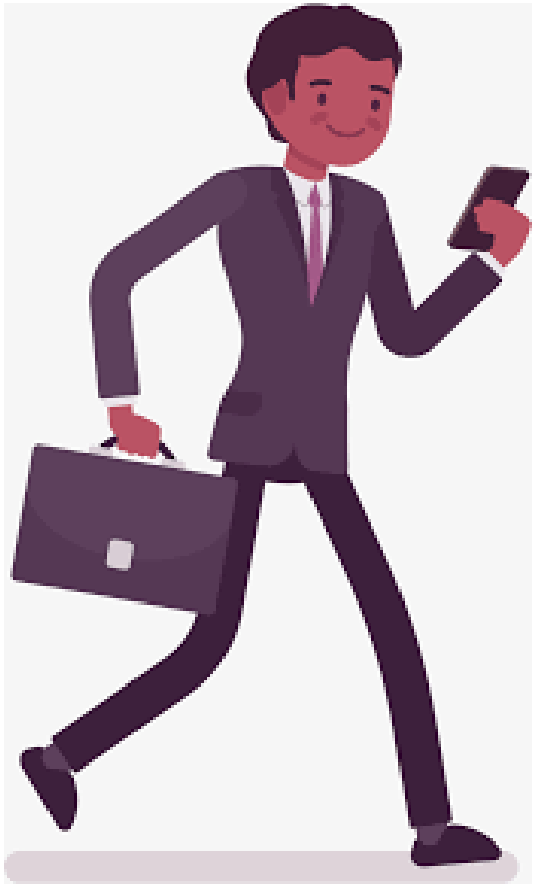

Introdução

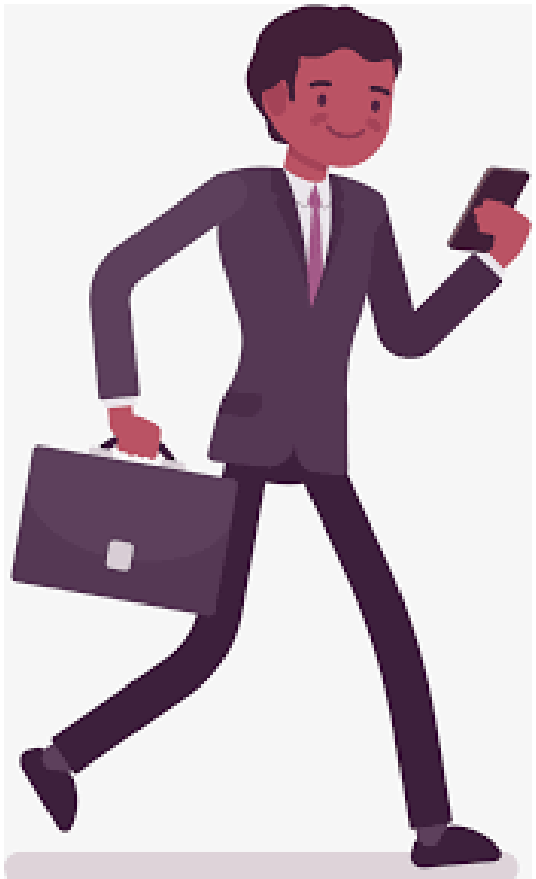

- O elevado aumento do uso de dispositivos móveis criou um ambiente propício para AM;

Introdução

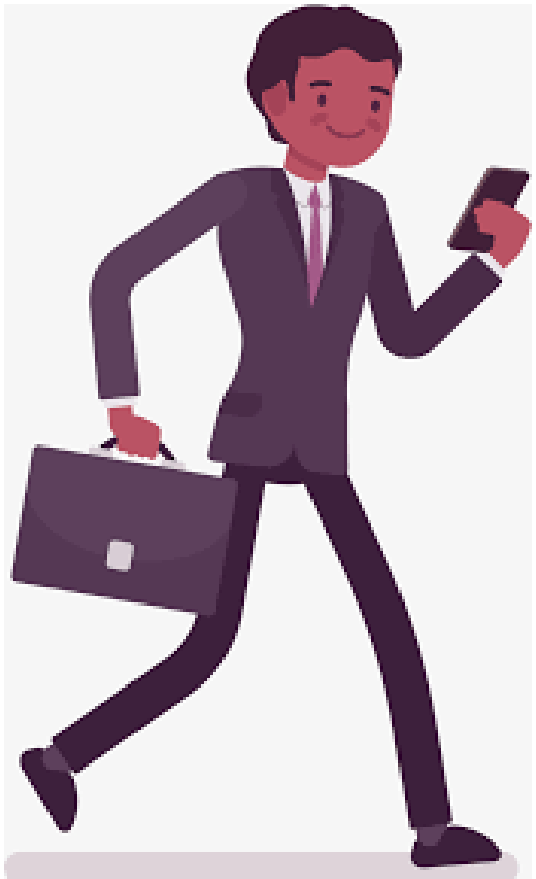

- O elevado aumento do uso de dispositivos móveis criou um ambiente propício para AM;
- Sites de busca, compras em tempo real, reconhecimento facial, entre outras aplicações;

Introdução

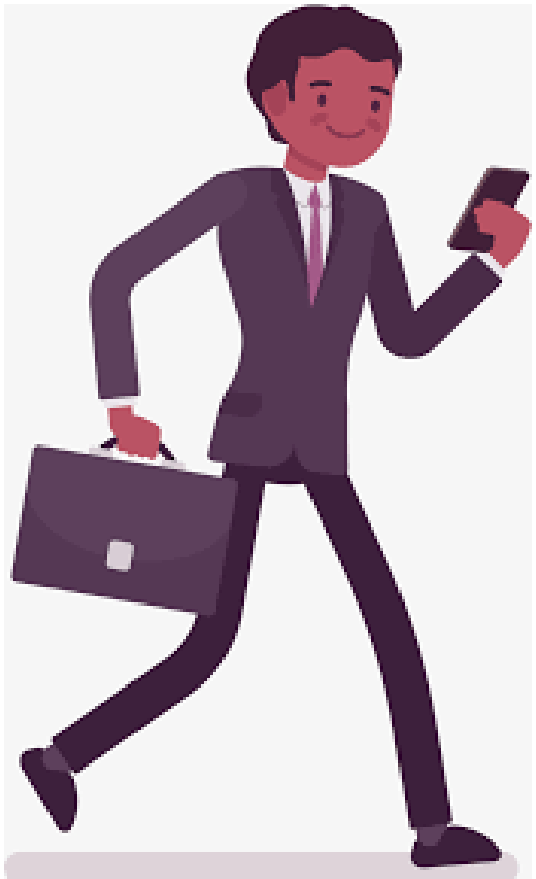

- O elevado aumento do uso de dispositivos móveis criou um ambiente propício para AM;
- Sites de busca, compras em tempo real, reconhecimento facial, entre outras aplicações;
- Mas não é de hoje que se usa AM. Ex.: OCR (*Optical character recognition)*;

Introdução

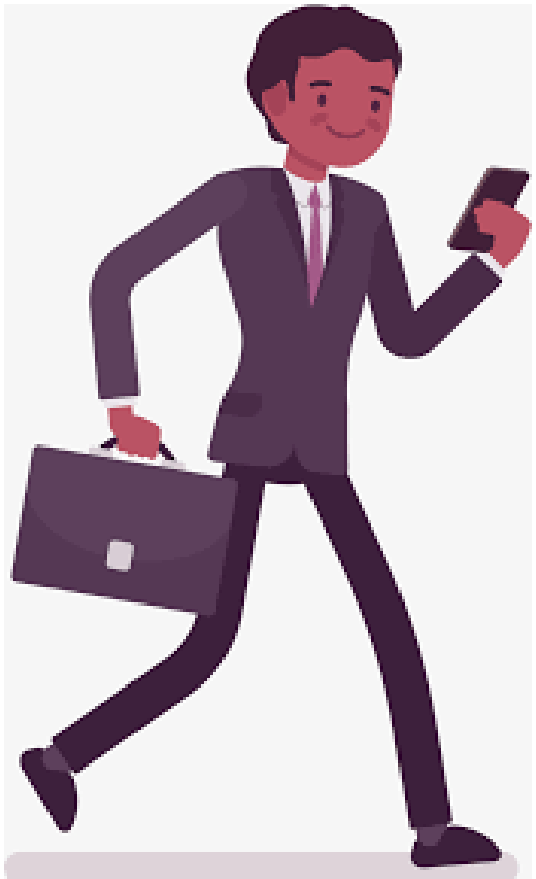

- O elevado aumento do uso de dispositivos móveis criou um ambiente propício para AM;
- Sites de busca, compras em tempo real, reconhecimento facial, entre outras aplicações;
- Mas não é de hoje que se usa AM. Ex.: OCR (*Optical character recognition)*;
- Arthur Samuel em 1959, definiu AM como uma área de estudo que dá ao computador a habilidade de aprender uma atividade, mesmo sem ter sido explicitamente programado para tal;

Introdução

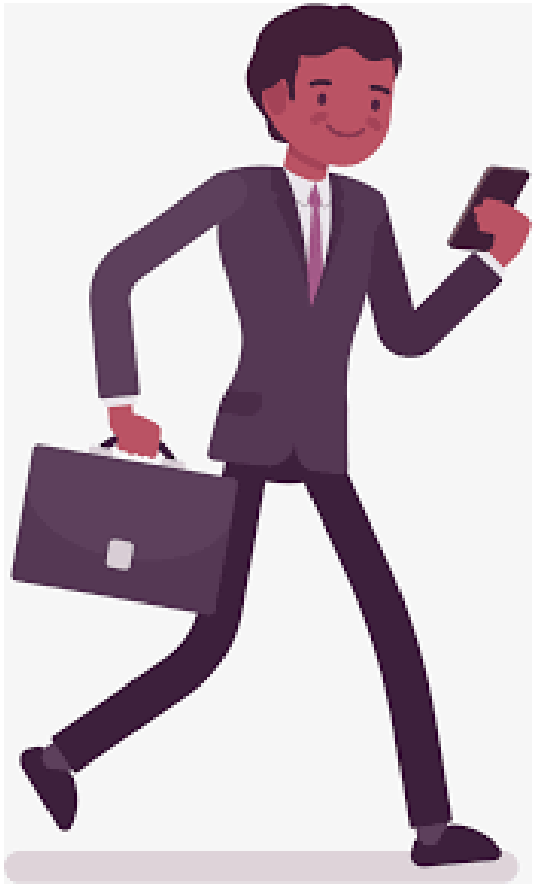

- O elevado aumento do uso de dispositivos móveis criou um ambiente propício para AM;
- Sites de busca, compras em tempo real, reconhecimento facial, entre outras aplicações;
- Mas não é de hoje que se usa AM. Ex.: OCR (*Optical character recognition)*;
- Arthur Samuel em 1959, definiu AM como uma área de estudo que dá ao computador a habilidade de aprender uma atividade, mesmo sem ter sido explicitamente programado para tal;
- Definição formal "o estudo de algoritmos que melhoram a performance P de uma tarefa T com experiência E". Ex.: Jogo de Damas.

Introdução

Introdução

- Componentes básicos para a aplicação de um algoritmo de AM a um problema:
  1. Conjunto de dados;
  2. Função hipótese;
  3. Inexistência de solução analítica.

Introdução

- O Conjunto de dados pode ser dividido em:
  - Treinamento;
  - Validação;
  - Testes;
  - Ajustes (*tuning*).

Introdução

- O Conjunto de dados pode ser dividido em:
  - Treinamento;
  - Validação;
  - Testes;
  - Ajustes (*tuning*).
- Para todos os conjuntos de dados tem-se:
  - Atributos (*features*);
  - Instâncias (*instances*) ou amostras (*samples*);
  - Rótulo (*target*).

Métodos de Aprendizagem

Métodos de Aprendizagem

- **Aprendizado Supervisionado**: O algoritmo é treinado com dados históricos e, a partir desses, deseja-se prever dados futuros.

Métodos de Aprendizagem

- **Aprendizado Supervisionado**: O algoritmo é treinado com dados históricos e, a partir desses, deseja-se prever dados futuros.

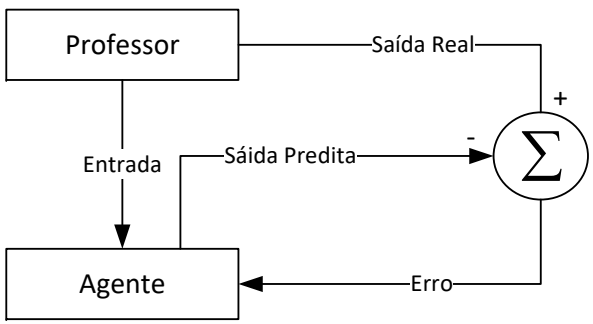

Mercado de Ações

Bancos

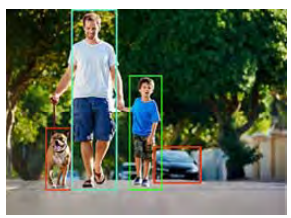
Imagens

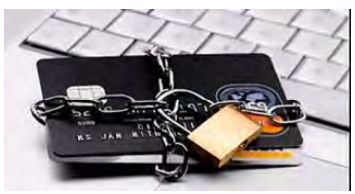
Cartões de Crédito

Medicina

Industria

Métodos de Aprendizagem

Métodos de Aprendizagem

- **Aprendizado Não supervisionado**: São usados somente dados de entrada no treinamento e não se tem a informação do valor a ser predito.

Métodos de Aprendizagem

- **Aprendizado Não supervisionado**: São usados somente dados de entrada no treinamento e não se tem a informação do valor a ser predito.

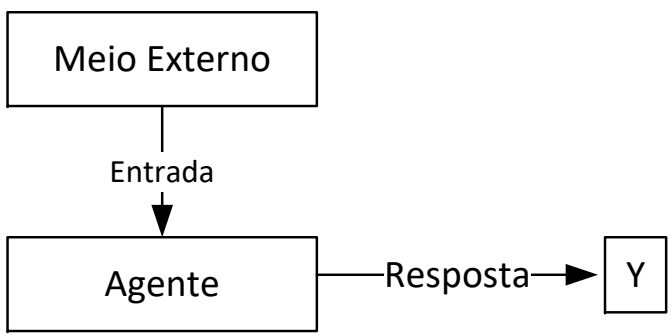

Marketing

Biologia

Seguro

Terremotos

Métodos de Aprendizagem

Métodos de Aprendizagem

- **Aprendizado por Reforço**: Tenta-se achar a melhor forma de alcançar um objetivo e o algoritmo aprende com o passar das iterações.

Métodos de Aprendizagem

- **Aprendizado por Reforço**: Tenta-se achar a melhor forma de alcançar um objetivo e o algoritmo aprende com o passar das iterações.

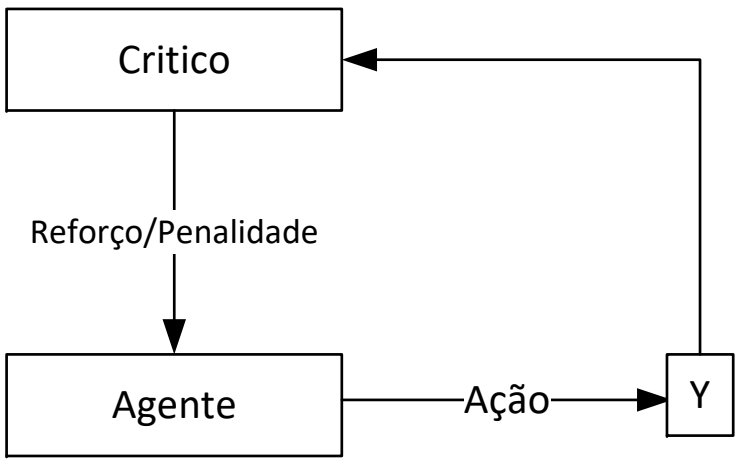

Veículo autônomo

Robô enceradeira

Métodos de Aprendizagem

Métodos de Aprendizagem

- **Algoritmos Evolucionários**: O objetivo é encontrar parâmetros em um espaço de busca de modo a minimizar ou maximizar uma função objetiva definida.

Métodos de Aprendizagem

- **Algoritmos Evolucionários**: O objetivo é encontrar parâmetros em um espaço de busca de modo a minimizar ou maximizar uma função objetiva definida.

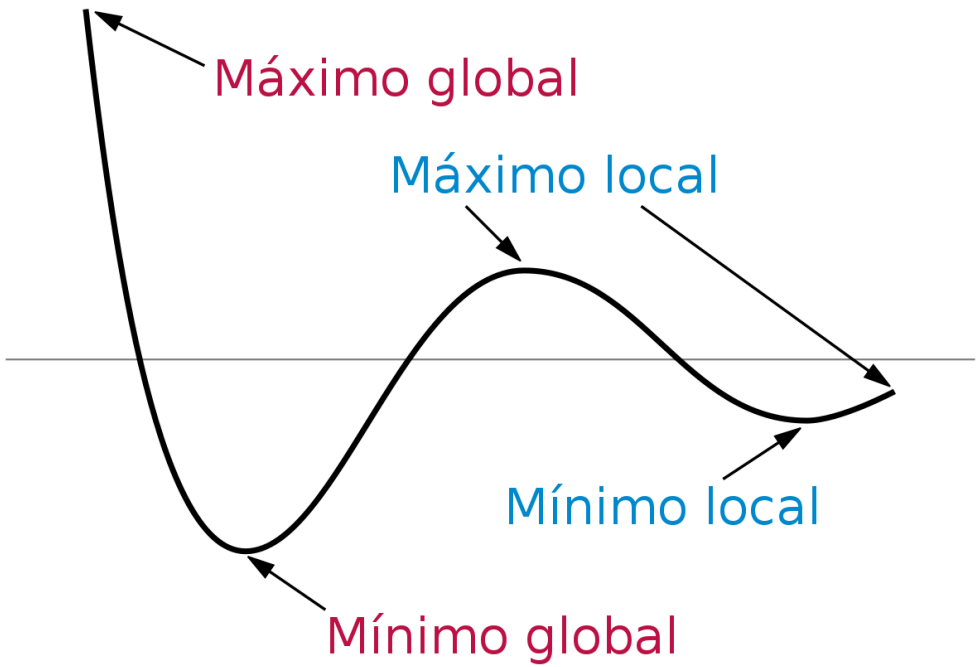

Tipos de Algorítmos de Aprendizado de Máquina

[1] Algoritmos explorados neste minicurso.

Tipos de Algorítmos de Aprendizado de Máquina

Supervisionado	N-supervisionado	Reforço	Evolucionários
K-NN[1]	K-means	Q-Learning	GA
SVM[1]	SOM	SARSA	PSO
MLP	Autoencoders	Deep Learning	ABC

[1] Algoritmos explorados neste minicurso.

k-NN *(K-nearest neighbors)*

k-NN *(K-nearest neighbors)*

- Algoritmo baseado em instâncias para classificação ou regressão;

k-NN *(K-nearest neighbors)*

- Algoritmo baseado em instâncias para classificação ou regressão;
- Funcionamento:

k-NN *(K-nearest neighbors)*

- Algoritmo baseado em instâncias para classificação ou regressão;
- Funcionamento:
  1. Dada $\mathbf{X}_i$ encontrar k instâncias vizinhas;

k-NN *(K-nearest neighbors)*

- Algoritmo baseado em instâncias para classificação ou regressão;
- Funcionamento:
  1. Dada $\mathbf{X}_i$ encontrar k instâncias vizinhas;
  2. Supondo que cada instância seja descrita por $\mathbf{X} = [X_{i1}, X_{i2}, \ldots, X_{im}]$, para classificação, a distância entre duas instâncias $\mathbf{X}_i$ e $\mathbf{X}_j$, denotada por $d(\mathbf{X}_i, \mathbf{X}_j)$, é definida por

$$d(\mathbf{X}_i, \mathbf{X}_j) = \sqrt{\sum_{r=1}^{m} (X_{ir} - X_{jr})^2}$$

k-NN *(K-nearest neighbors)*

- Algoritmo baseado em instâncias para classificação ou regressão;
- Funcionamento:
  1. Dada $\mathbf{X}_i$ encontrar k instâncias vizinhas;
  2. Supondo que cada instância seja descrita por $\mathbf{X} = [X_{i1}, X_{i2}, \ldots, X_{im}]$, para classificação, a distância entre duas instâncias $\mathbf{X}_i$ e $\mathbf{X}_j$, denotada por $d(\mathbf{X}_i, \mathbf{X}_j)$, é definida por

$$d(\mathbf{X}_i, \mathbf{X}_j) = \sqrt{\sum_{r=1}^{m} (X_{ir} - X_{jr})^2}$$

  3. Já nos problemas de regressão,

$$\hat{f}(\mathbf{X}_i) \leftarrow \frac{\sum_{i=1}^{k} f(\mathbf{X}_i)}{k}.$$

k-NN *(K-nearest neighbors)*

k-NN *(K-nearest neighbors)*

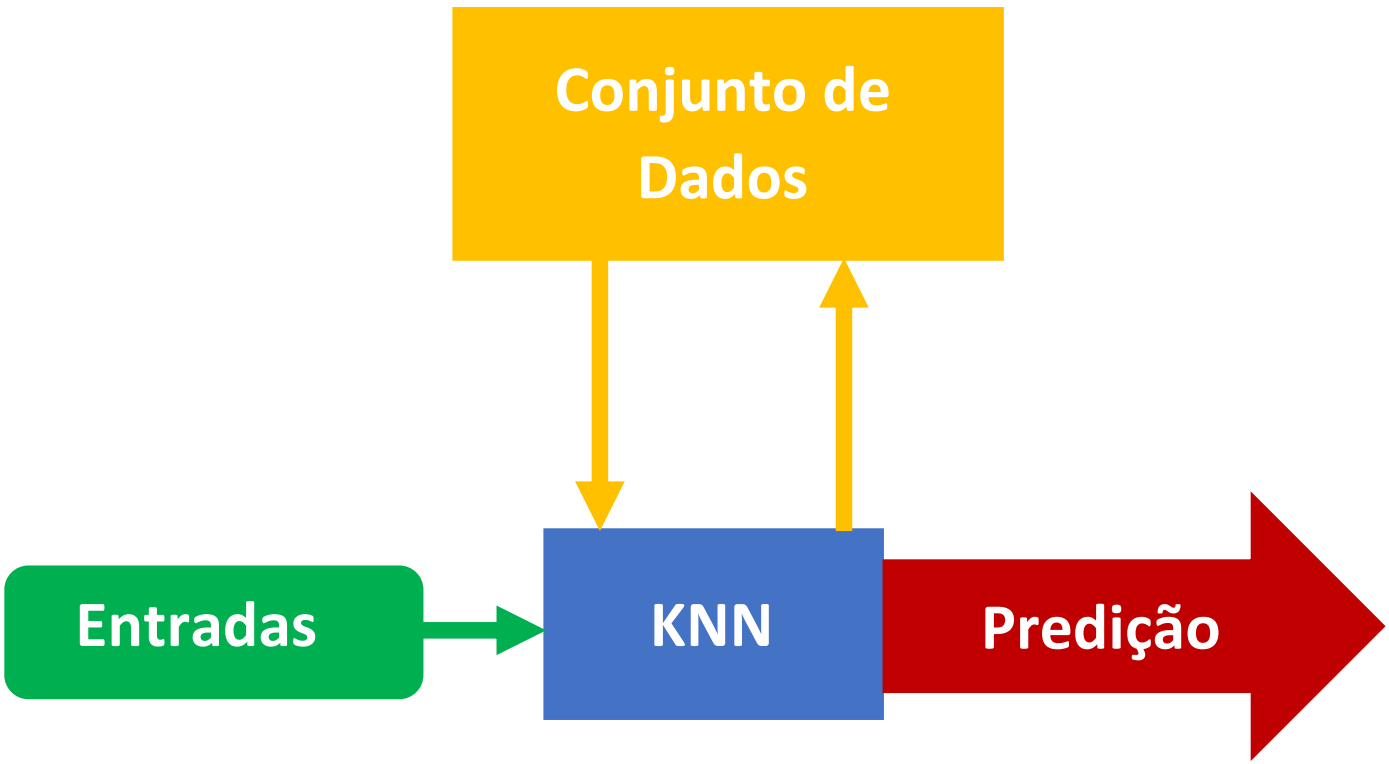

SVM (Máquinas de Vetores de Suporte)

SVM (Máquinas de Vetores de Suporte)

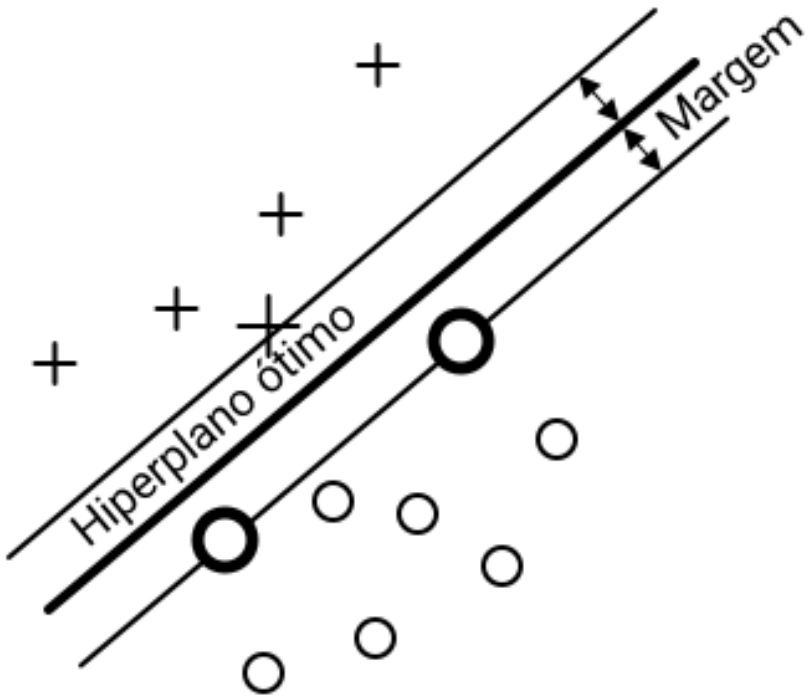

SVM (Máquinas de Vetores de Suporte)

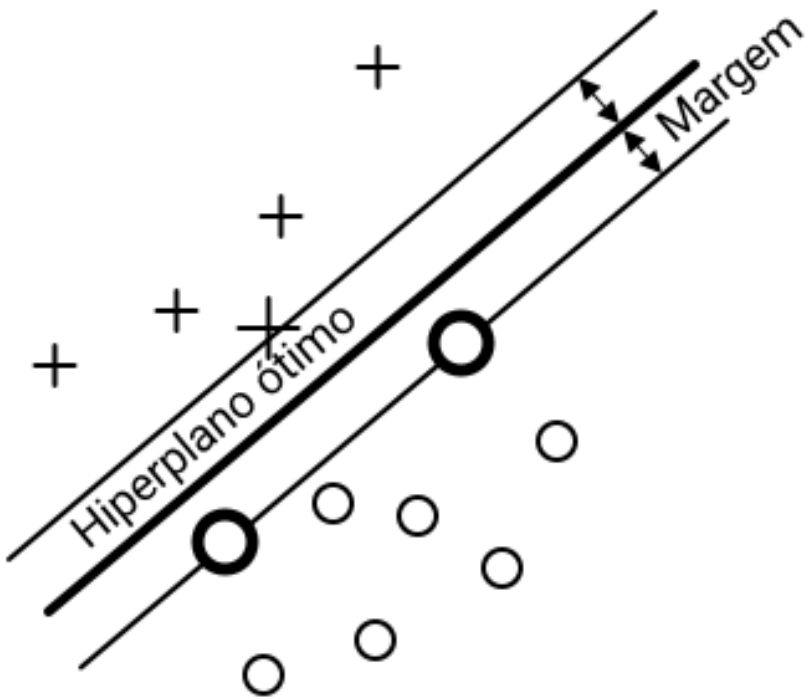

- SVM (*Support vector machine* foi introduzida por Vapnik em 1995;

SVM (Máquinas de Vetores de Suporte)

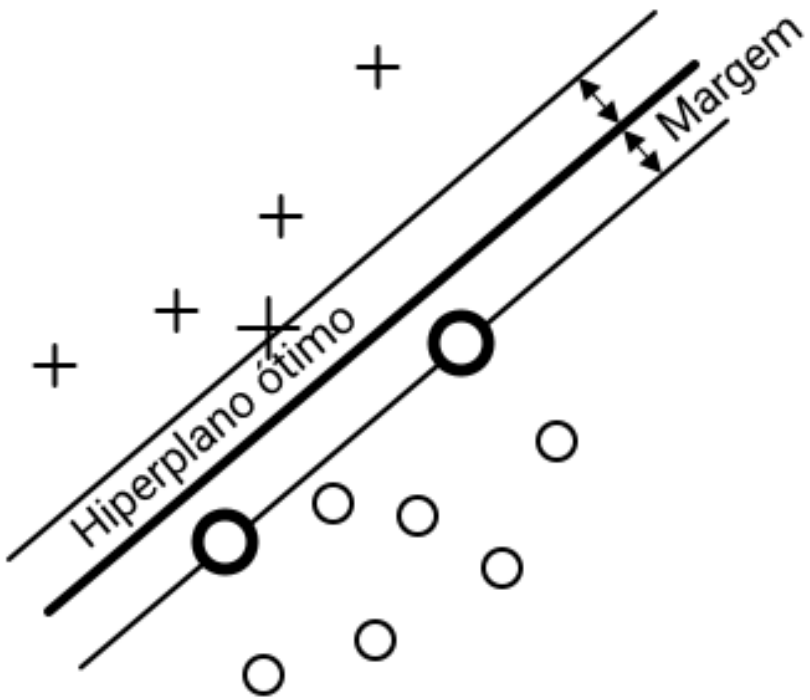

- SVM (*Support vector machine* foi introduzida por Vapnik em 1995;
- A técnica pode resolver tanto problemas linearmente separáveis como não-linearmente separáveis;

SVM (Máquinas de Vetores de Suporte)

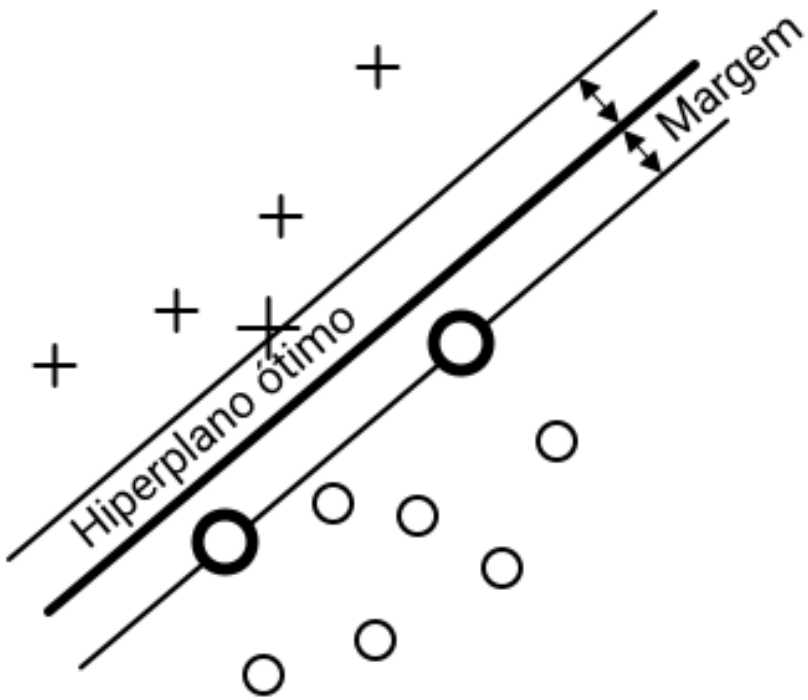

- SVM (*Support vector machine* foi introduzida por Vapnik em 1995;
- A técnica pode resolver tanto problemas linearmente separáveis como não-linearmente separáveis;
- No contexto de classificação funciona conforme a Figura ao lado;

SVM (Máquinas de Vetores de Suporte)

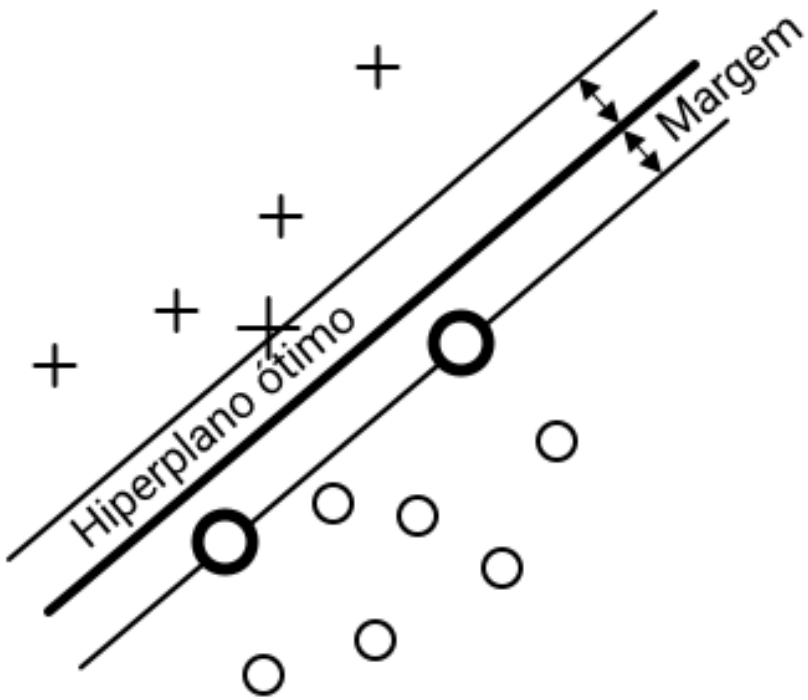

- SVM (*Support vector machine* foi introduzida por Vapnik em 1995;
- A técnica pode resolver tanto problemas linearmente separáveis como não-linearmente separáveis;
- No contexto de classificação funciona conforme a Figura ao lado;
- Para lidar com problemas não linearmente separáveis, a SVM mapeia por meio de funções de *kernel* o conjunto de dados não linear em um espaço n-dimensional em que os dados podem ser linearmente separáveis;

SVM (Máquinas de Vetores de Suporte)

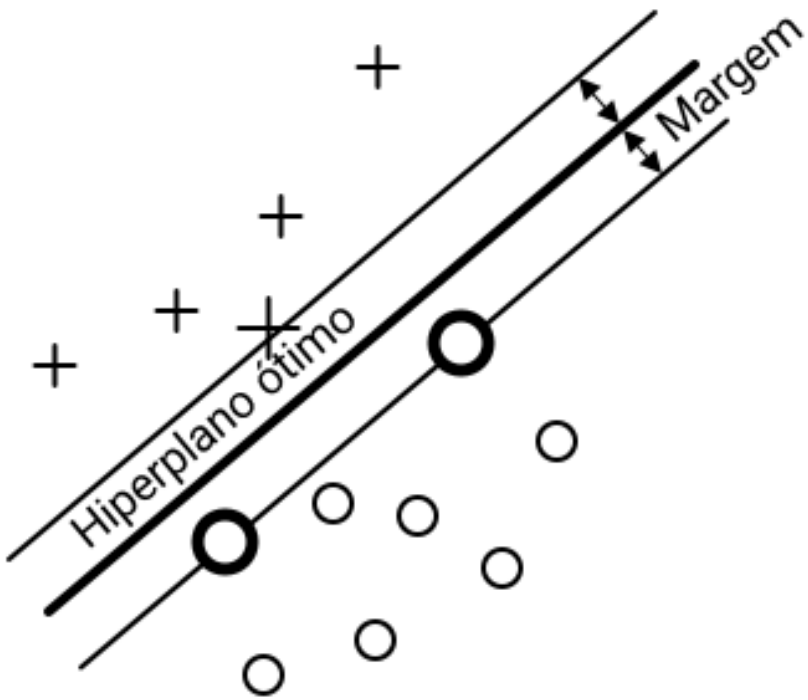

- SVM (*Support vector machine* foi introduzida por Vapnik em 1995;
- A técnica pode resolver tanto problemas linearmente separáveis como não-linearmente separáveis;
- No contexto de classificação funciona conforme a Figura ao lado;
- Para lidar com problemas não linearmente separáveis, a SVM mapeia por meio de funções de *kernel* o conjunto de dados não linear em um espaço n-dimensional em que os dados podem ser linearmente separáveis;
- Assim, um novo conjunto de treinamento, linearmente separável, é obtido.

Máquinas de Vetores de Suporte

Máquinas de Vetores de Suporte

Professor Vladimir Vapnik

Máquinas de Vetores de Suporte

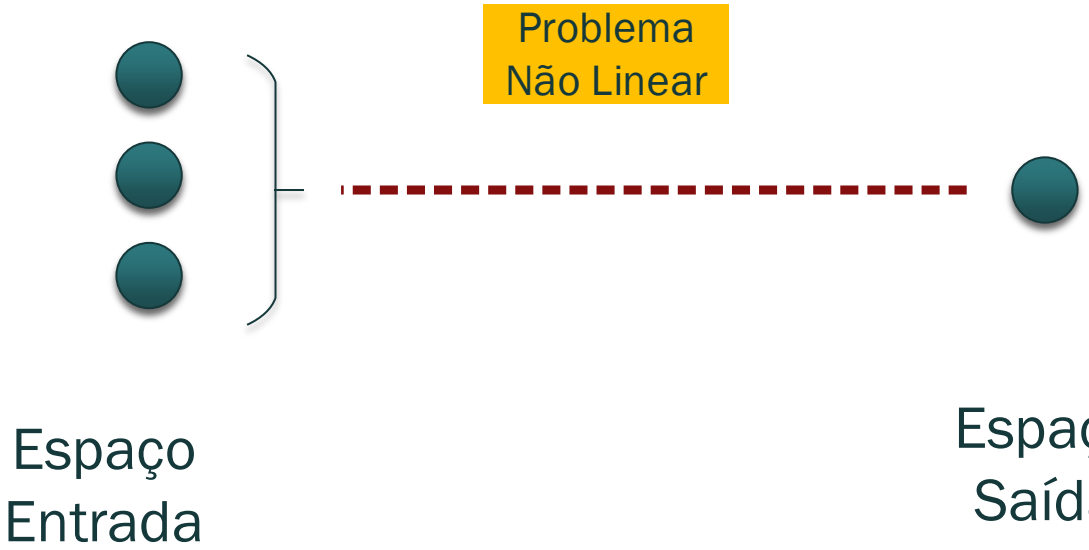

Máquinas de Vetores de Suporte

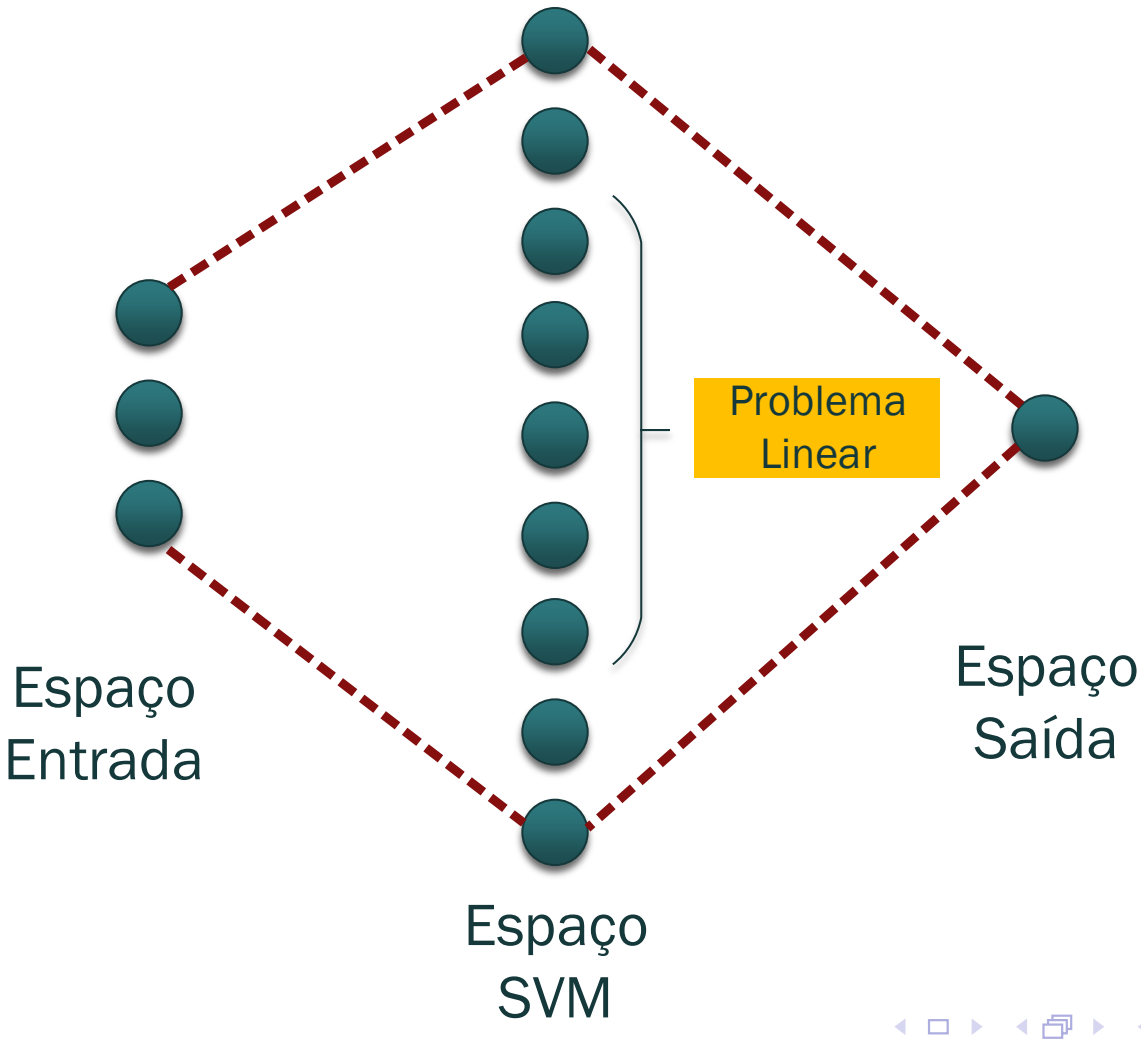

Máquinas de Vetores de Suporte: SVM e SVR

Máquinas de Vetores de Suporte: SVM e SVR

SVM

Usada para Classificação

Máquinas de Vetores de Suporte: SVM e SVR

SVM

Usada para Classificação

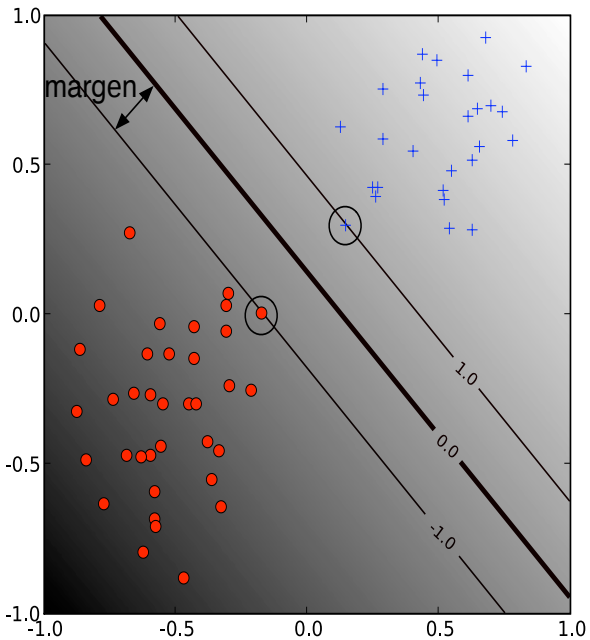

Máquinas de Vetores de Suporte: SVM e SVR

SVM

Usada para Classificação

SVR

Usada para Regressão

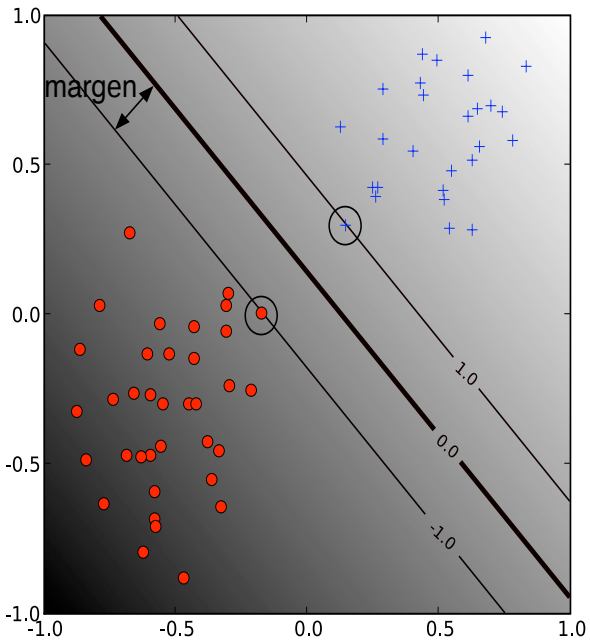

Máquinas de Vetores de Suporte: SVM e SVR

SVM

Usada para Classificação

SVR

Usada para Regressão

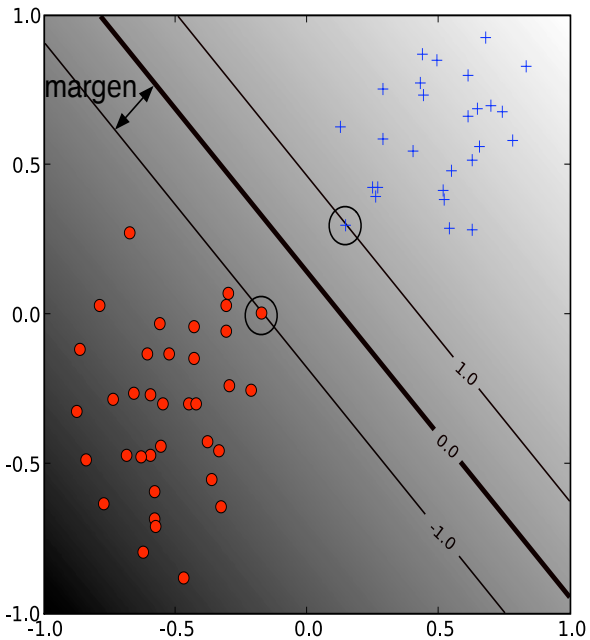

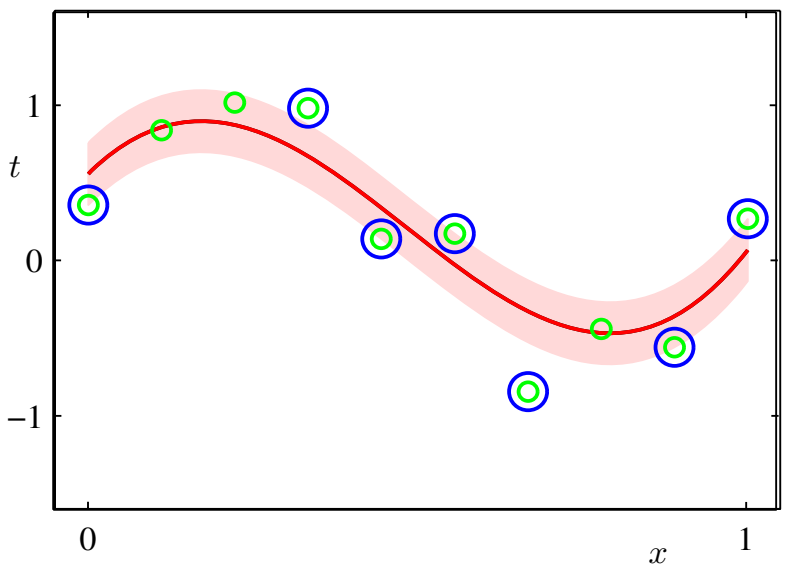

Regressão por Vetores de Suporte (SVR)

Regressão por Vetores de Suporte (SVR)

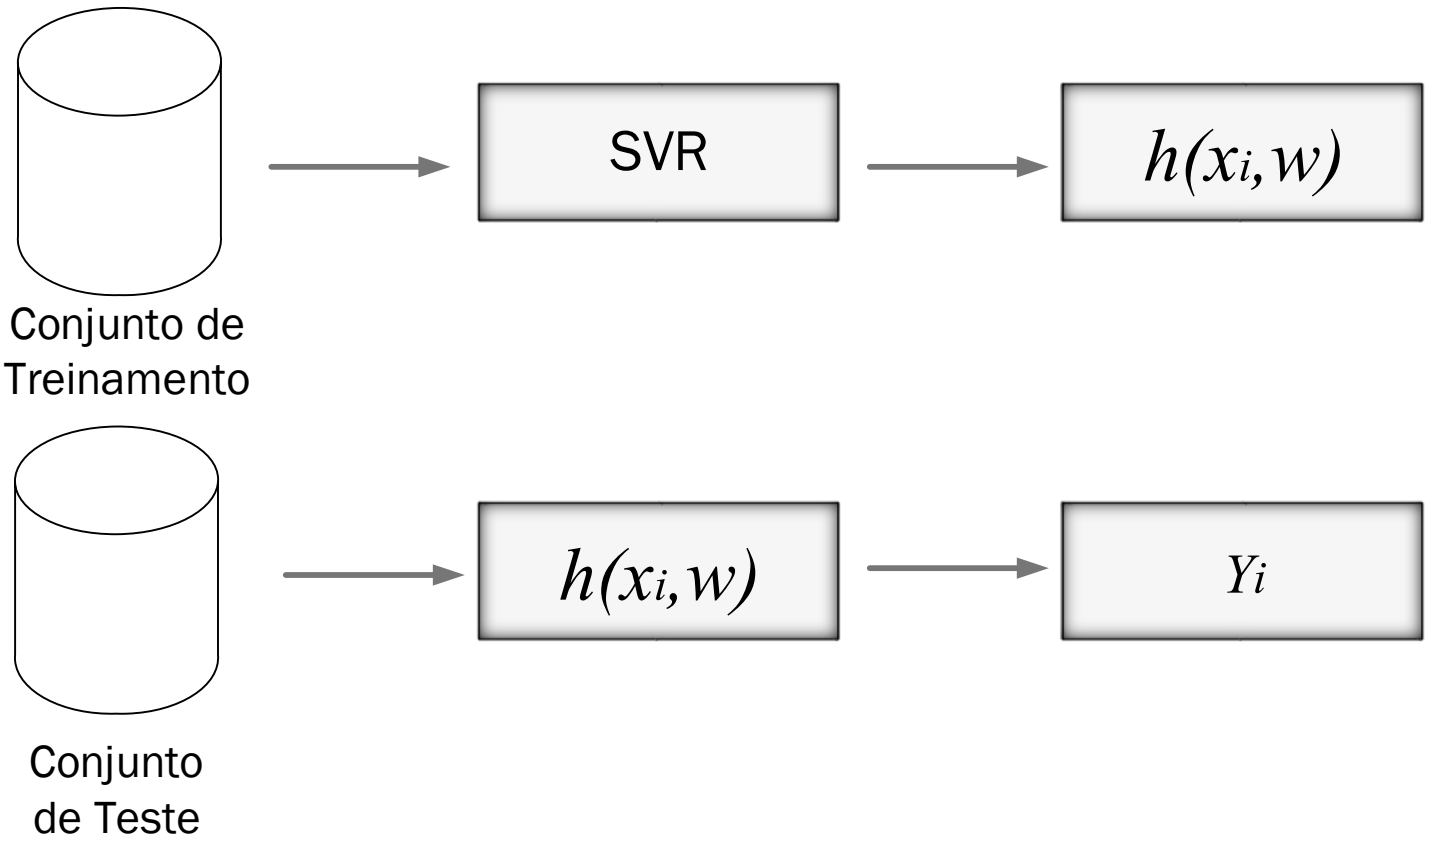

Regressão por Vetores de Suporte (SVR): ε-SVR

Regressão por Vetores de Suporte (SVR): ε-SVR

$$h(\mathbf{x}_i, \mathbf{w}) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \ ,$$

Regressão por Vetores de Suporte (SVR): ε-SVR

$$h(\mathbf{x}_i, \mathbf{w}) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \ ,$$

minimizar:

$$\min_{\mathbf{w},b} \left[\frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^{\ell} (\xi_i + \hat{\xi}_i) \right) \right]$$

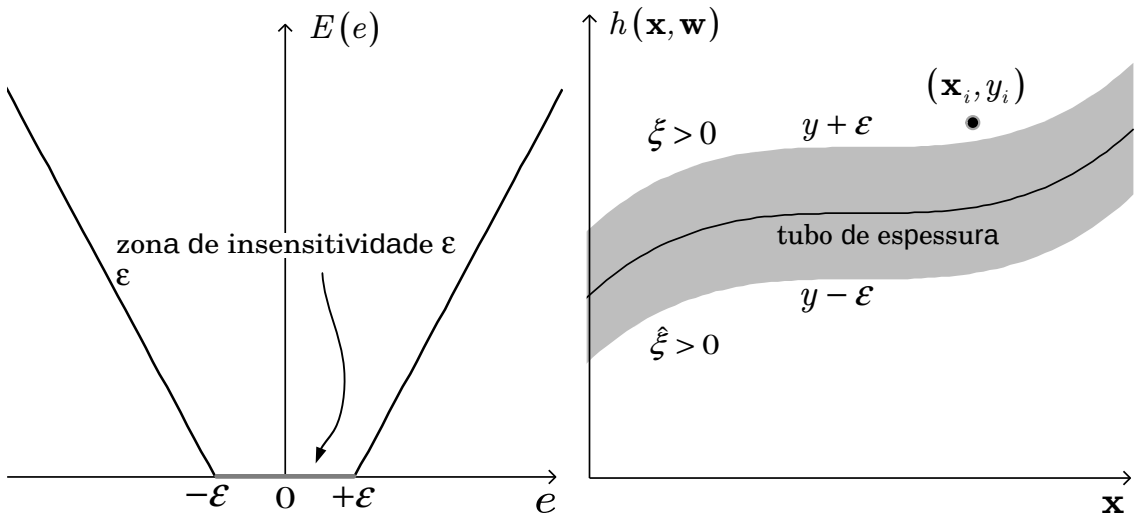

Regressão por Vetores de Suporte (SVR): ε-SVR

$$h(\mathbf{x}_i, \mathbf{w}) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \ ,$$

minimizar:

$$\min_{\mathbf{w},b} \left[\frac{1}{2} \|\mathbf{w}\|^2 + C \left(\sum_{i=1}^{\ell} (\xi_i + \hat{\xi}_i) \right) \right]$$

restrito a:

$$\begin{cases} y_i - h(\mathbf{x}_i, \mathbf{w}) \ \leq \varepsilon + \xi \\ h(\mathbf{x}_i, \mathbf{w}) - y_i \leq \varepsilon + \hat{\xi} \\ \xi, \hat{\xi} \geq 0 \end{cases} ,$$

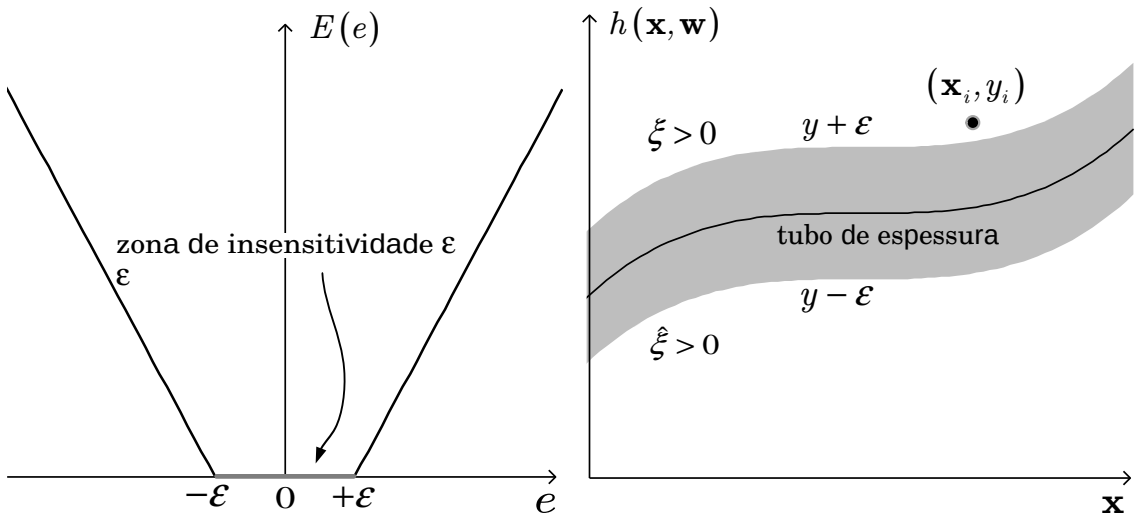

Regressão por Vetores de Suporte (SVR): ε-SVR Kernels

Regressão por Vetores de Suporte (SVR): ε-SVR Kernels

$$h(\mathbf{x}_i, \mathbf{w}) = \sum_{j=1}^{\ell} (\alpha - \alpha^*) \langle \Phi(\mathbf{x}_j), \Phi(\mathbf{x}_i) \rangle + b \ .$$

Regressão por Vetores de Suporte (SVR): ε-SVR Kernels

$$h(\mathbf{x}_i, \mathbf{w}) = \sum_{j=1}^{\ell} (\alpha - \alpha^*) \langle \Phi(\mathbf{x}_j), \Phi(\mathbf{x}_i) \rangle + b \ .$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \ .$$

Regressão por Vetores de Suporte (SVR): ε-SVR Kernels

$$h(\mathbf{x}_i, \mathbf{w}) = \sum_{j=1}^{\ell} (\alpha - \alpha^*) \langle \Phi(\mathbf{x}_j), \Phi(\mathbf{x}_i) \rangle + b \ .$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \ .$$

Kernel	Expressão	Parâmetros
Polinomial	$K(\mathbf{x}_i, \mathbf{x}_j) = (\beta \langle \mathbf{x}_i, \mathbf{x}_j \rangle + c)^z$	β, c, z
Gaussiano	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right)$	σ
Laplaciano	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{\sigma}\right)$	σ

Sumário

1 Apresentação

2 Objetivos

3 Introdução

4 Revisitando técnicas e tecnologias de localização

5 Conceitos básicos aprendizado de máquina

6 Aprendizado de Máquina aplicado às técnicas de localização

7 Oportunidades e desafios

Predição de sinais com aprendizado de máquina

Predição de sinais com aprendizado de máquina

- Como prever a cobertura de uma região com SVR?

Predição de sinais com aprendizado de máquina

- Como prever a cobertura de uma região com SVR?

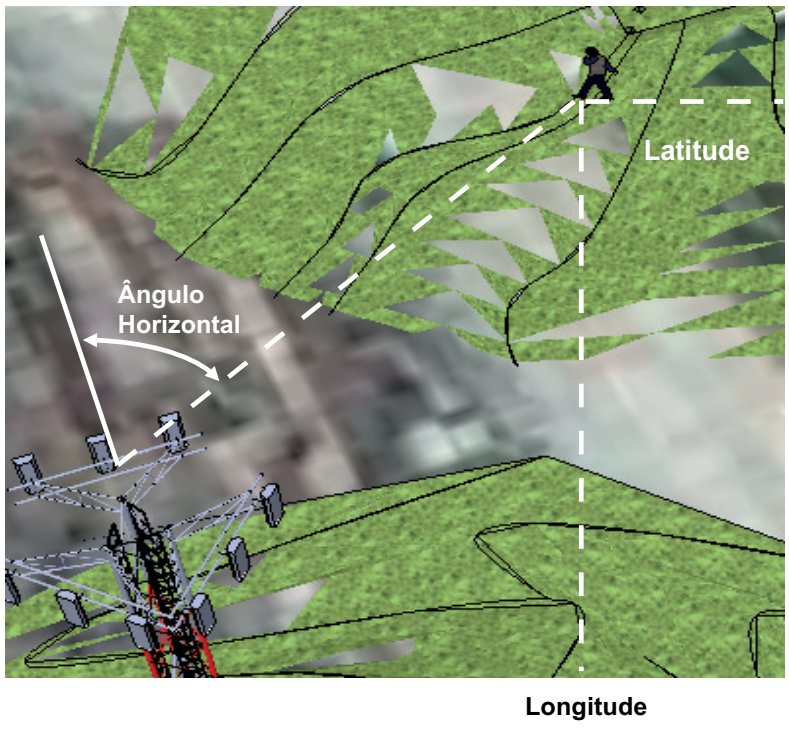

(a)

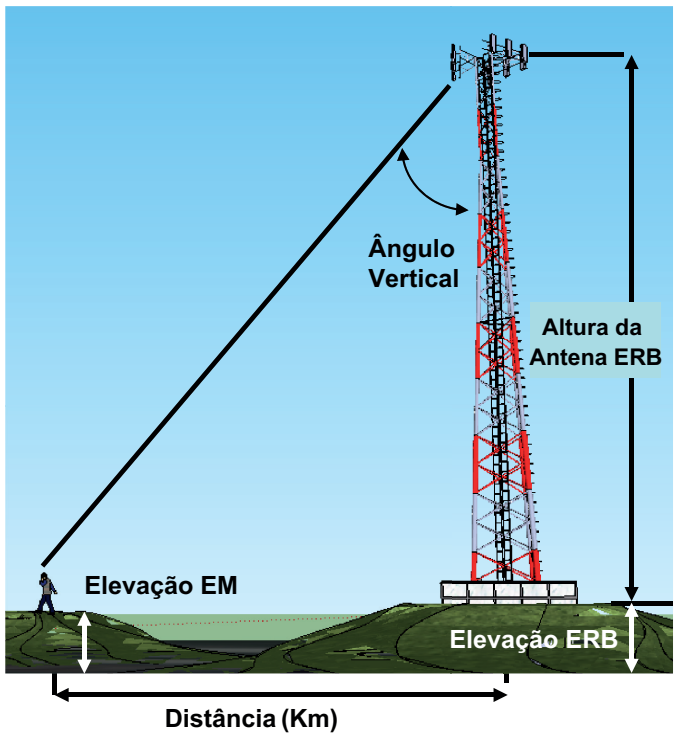

(b)

Predição de sinais com aprendizado de máquina

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições dos níveis de sinal do *scanner*;

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições dos níveis de sinal do *scanner*;
  2. Gerar o conjunto de dados para treinar a SVR;

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições dos níveis de sinal do *scanner*;
  2. Gerar o conjunto de dados para treinar a SVR;
  3. Treinar a SVR e ajustar os parâmetros C e ε;

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições dos níveis de sinal do *scanner*;
  2. Gerar o conjunto de dados para treinar a SVR;
  3. Treinar a SVR e ajustar os parâmetros C e ε;
  4. Apresentar à SVR uma instância nova x_i;

Predição de sinais com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições dos níveis de sinal do *scanner*;
  2. Gerar o conjunto de dados para treinar a SVR;
  3. Treinar a SVR e ajustar os parâmetros C e ε;
  4. Apresentar à SVR uma instância nova x_i;
  5. Verificar a predição realizada pela SVR.

RSSIs medidos em uma área urbana

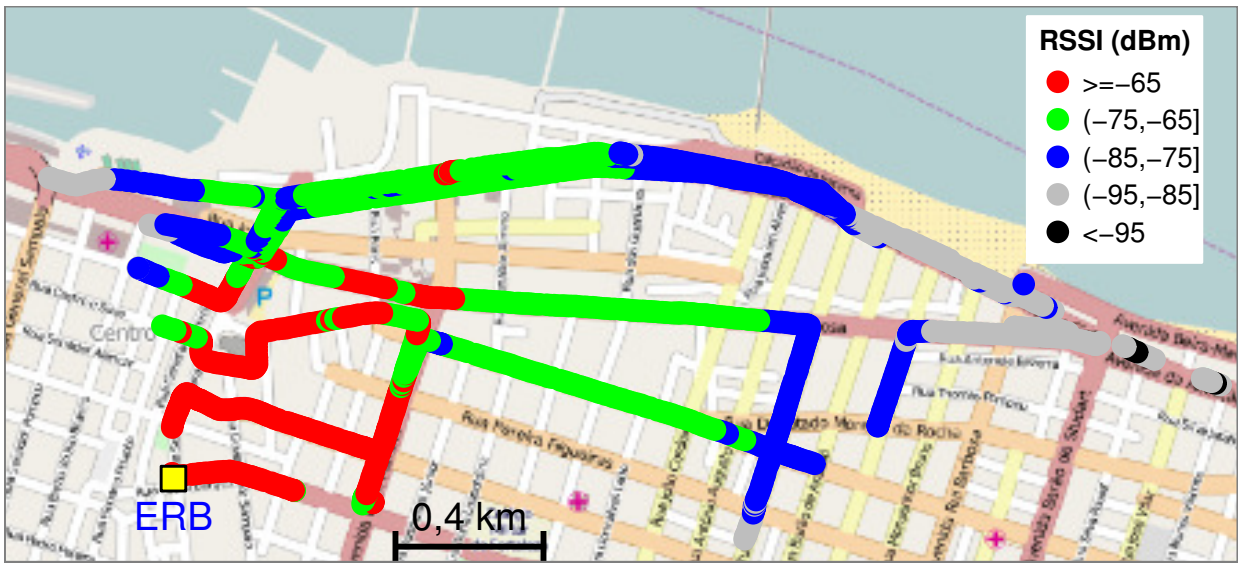

Figura: RSSIs medidos em uma área urbana da cidade de Fortaleza-CE. As cores indicam o RSSI em dBm e o quadrado amarelo representa a posição da ERB.

G-NetTrack: Coletar medidas RSSI *online*

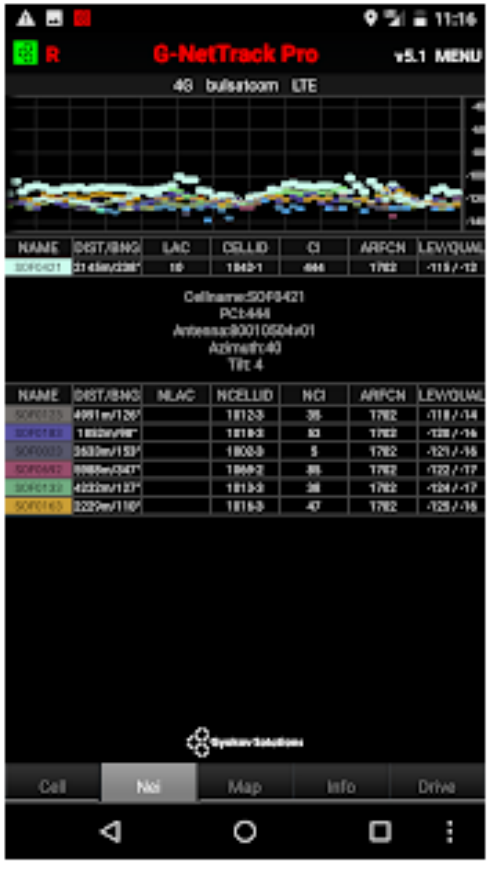

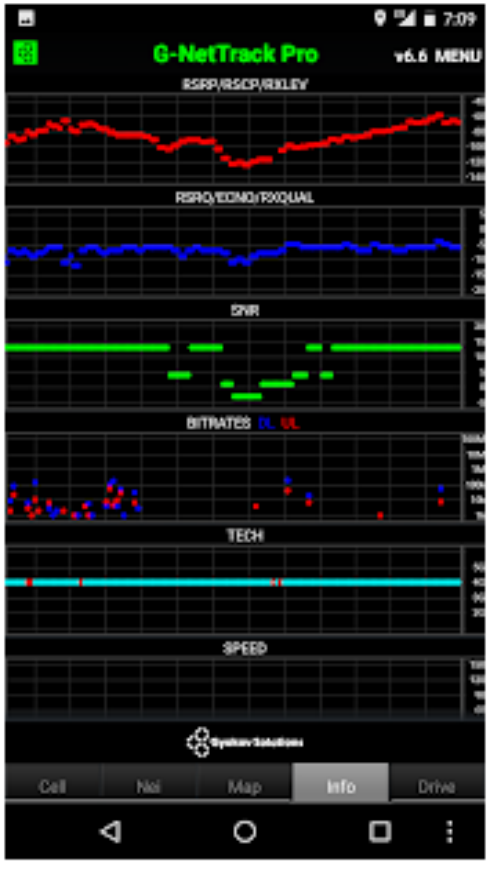

Construção do conjunto de dados

Tabela: Variáveis de entrada (*features*).

Atributo	Descrição
$x_{i,1}$	Latitude da EM
$x_{i,2}$	Longitude da EM
$x_{i,3}$	Elevação do terreno na posição da EM
$x_{i,4}$	Ângulo vertical entre a ERB e a EM
$x_{i,5}$	Ângulo horizontal entre a ERB e a EM
$x_{i,6}$	Perda horizontal no diagrama de radiação da antena
$x_{i,7}$	Perda vertical no diagrama de radiação da antena
$x_{i,8}$	Distância entre a ERB e a EM
$x_{i,9}$	Perda prevista pelo modelo de Okumura-Hata

Construção do conjunto de dados

Construção do conjunto de dados

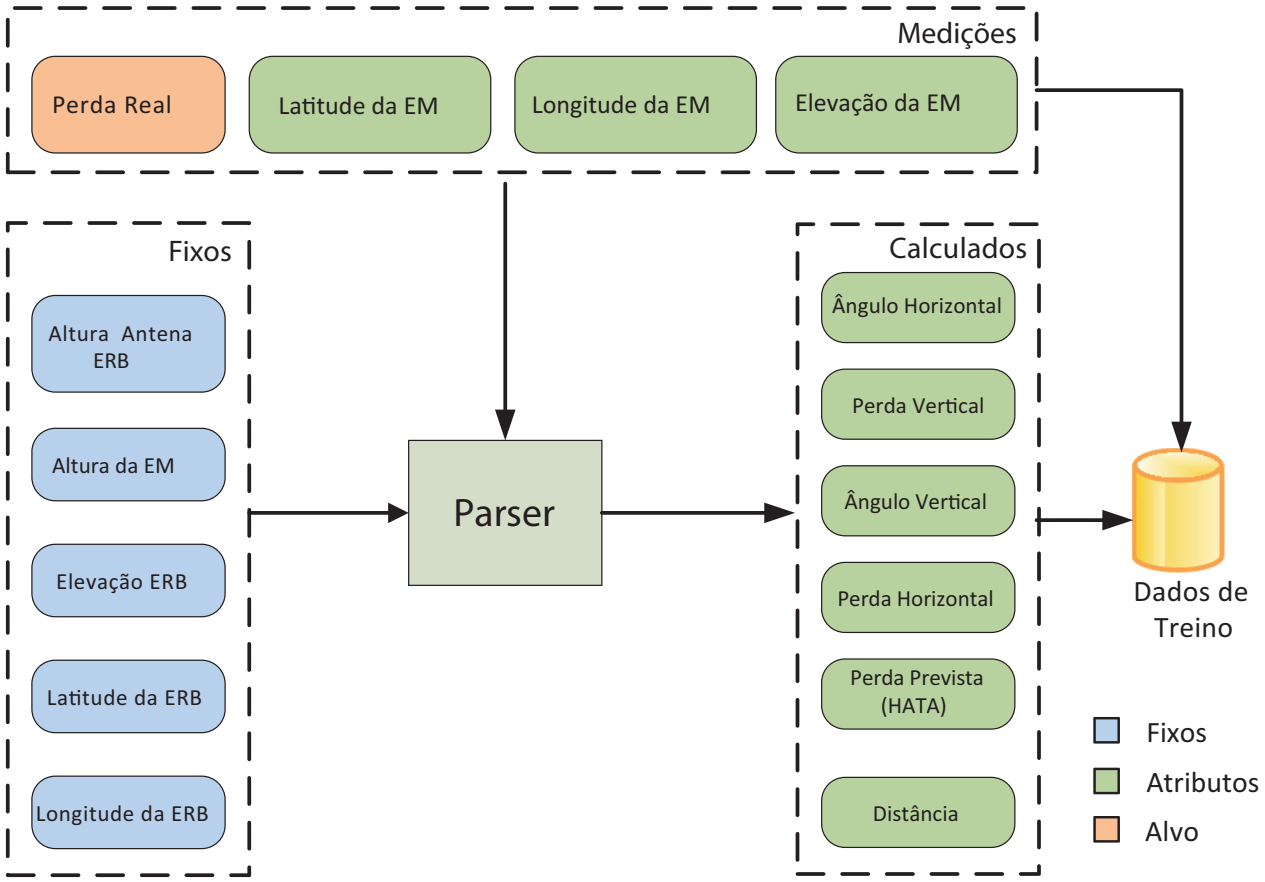

Figura: Diagrama do processo de construção do conjunto de dados.

Validação e treino

Validação e treino

- Cálculo da raiz do erro quadrático médio (RMSE, *Root mean square error*):

Validação e treino

- Cálculo da raiz do erro quadrático médio (RMSE, *Root mean square error*):

$$\bar{\mu} = \sqrt{\frac{1}{k}\sum_{j=1}^{k}\mu_j}$$

$$\mu_j = \sqrt{\frac{1}{\ell_j}\sum_{i=1}^{\ell_j}\left(y_i - h\left(\mathbf{x}_i, \mathbf{w}\right)\right)^2}\ ,$$

Validação e treino

Validação e treino

Figura: Funcionamento da técnica 10-*fold cross-validation* (divisão dos conjuntos de treino e teste).

Análise e Resultados

Análise e Resultados

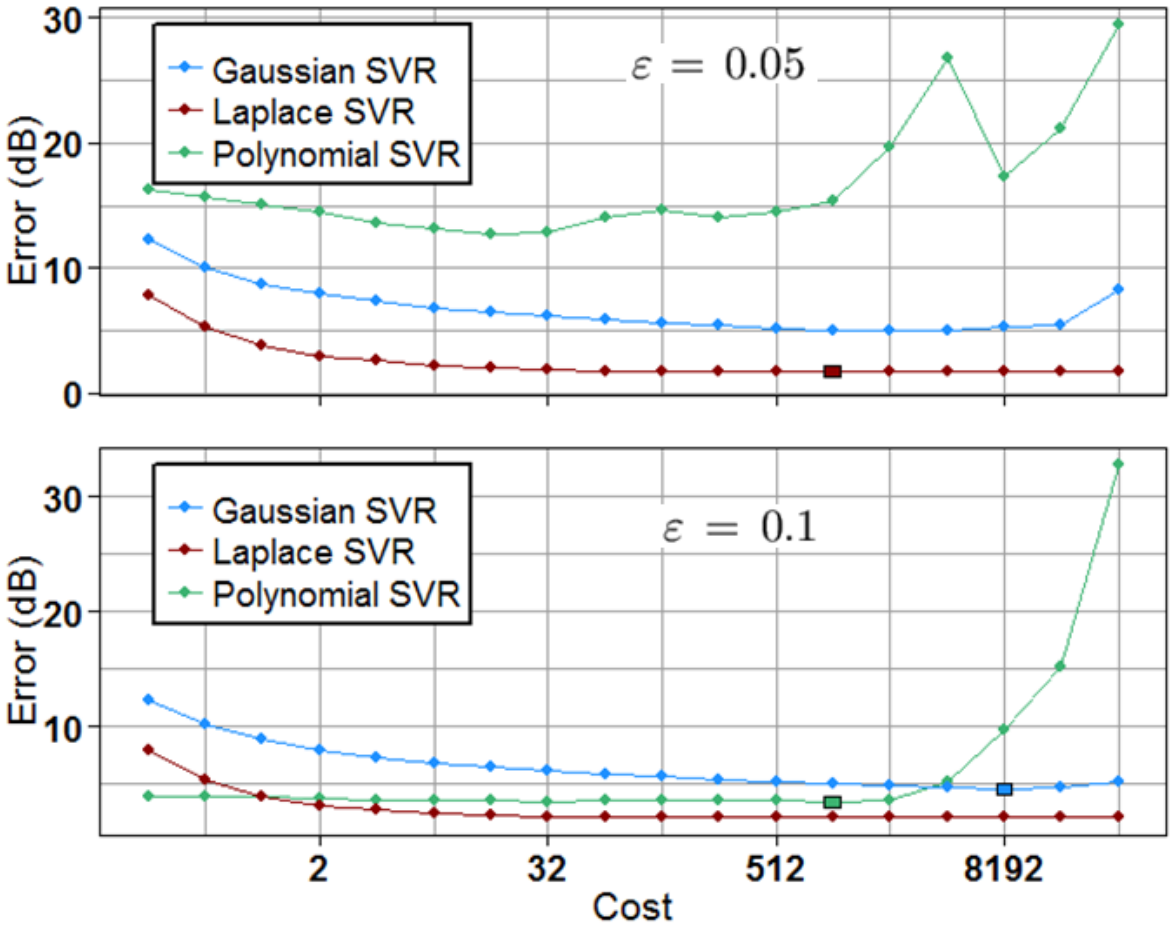

Figura: Variação do RMSE em função de C no processo de refinamento (*tuning*) do algoritmo SVR para os *kernels* Laplaciano, Gaussiano e polinomial.

Análise e Resultados

Análise e Resultados

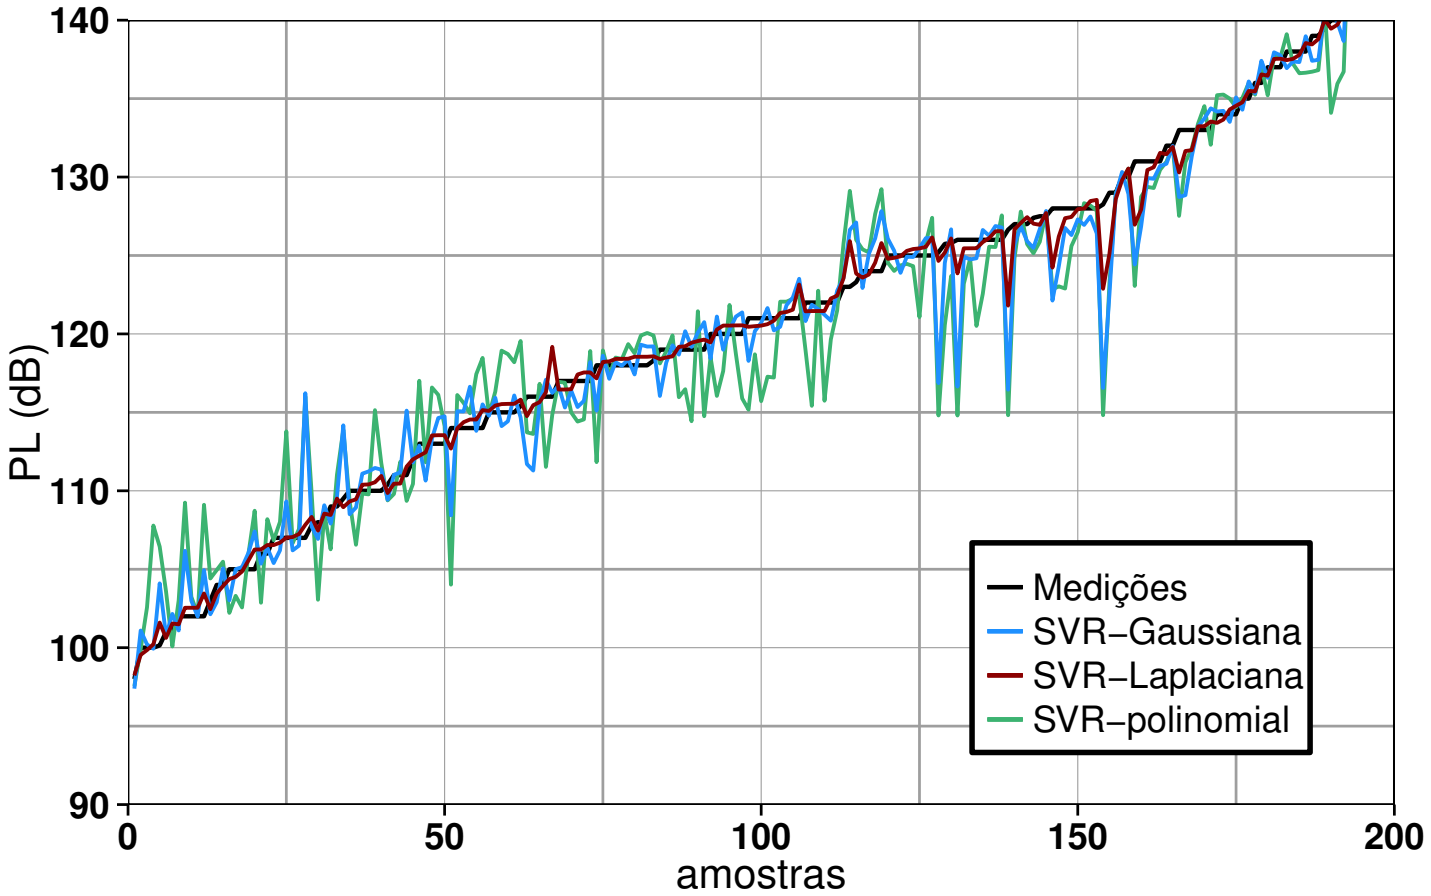

Figura: Comparação da predição da PL usando SVR com as medições reais em um conjunto de 10% das amostras.

Análise e Resultados

Análise e Resultados

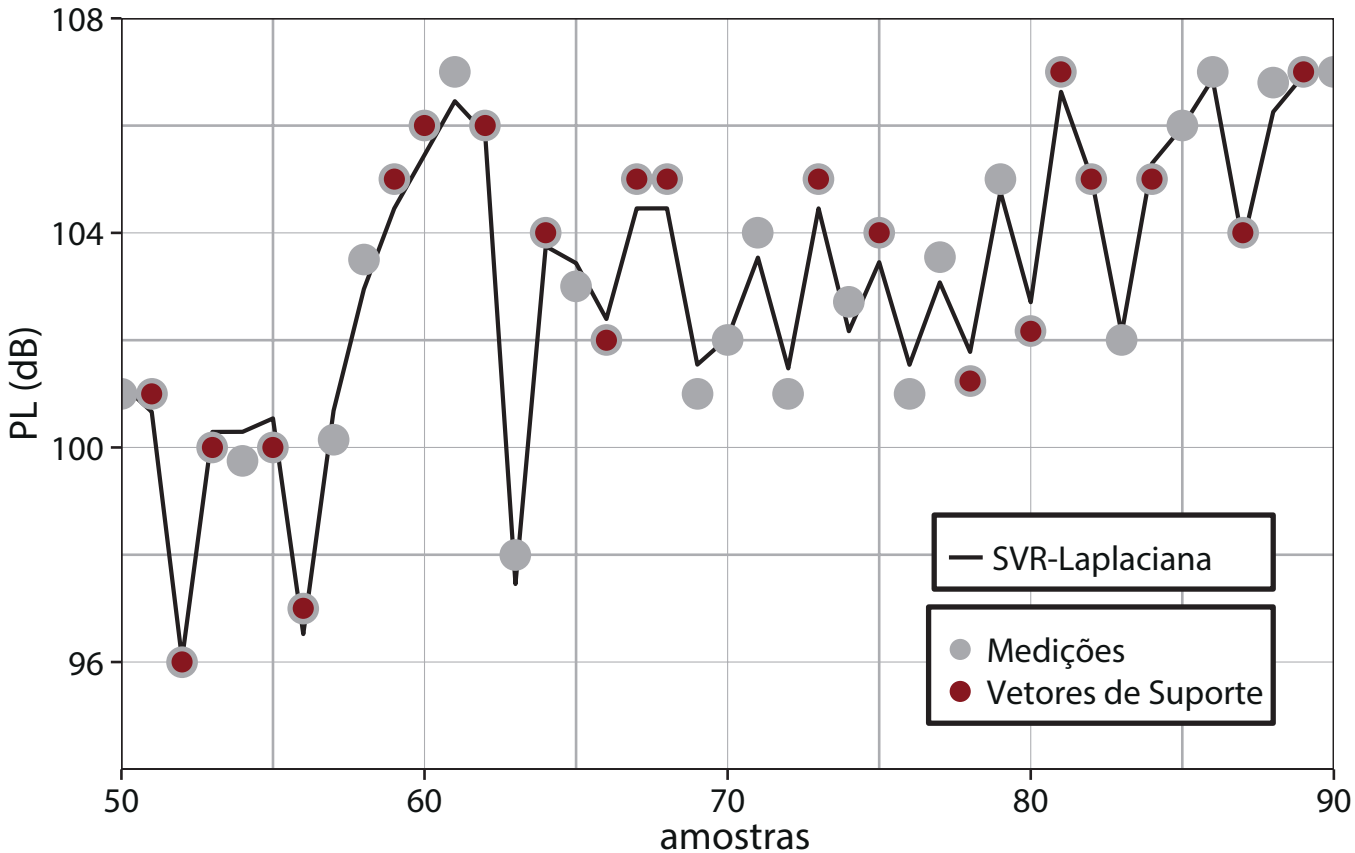

Figura: Vetores de suporte utilizados para obter a linha de regressão da PL (em dB) quando o *kernel* Laplaciano é adotado no algoritmo SVR.

Análise e Resultados

Análise e Resultados

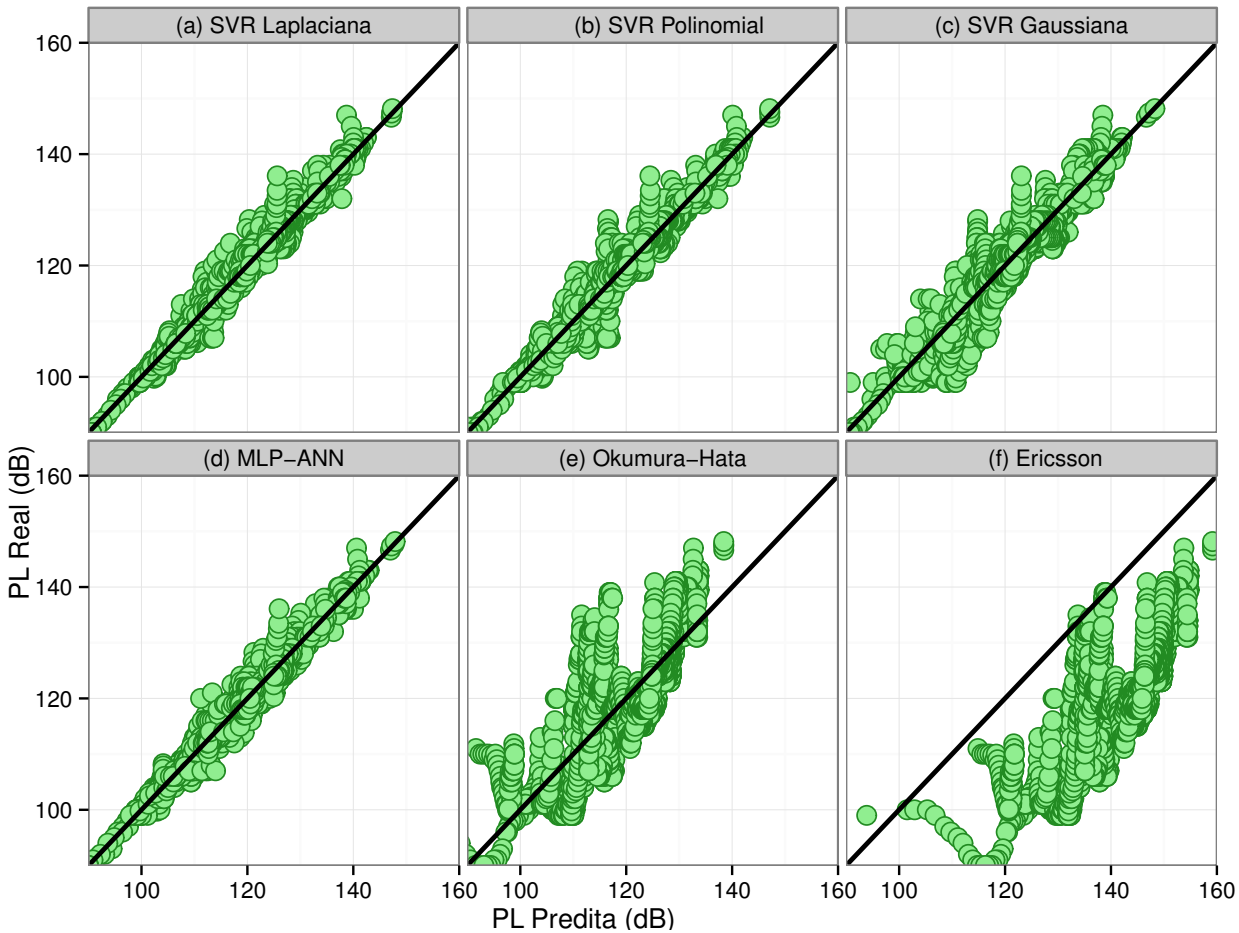

Figura: Comparação da PL real com a PL predita para todo o conjunto de dados.

Um método de localização com aprendizado de máquina

Um método de localização com aprendizado de máquina

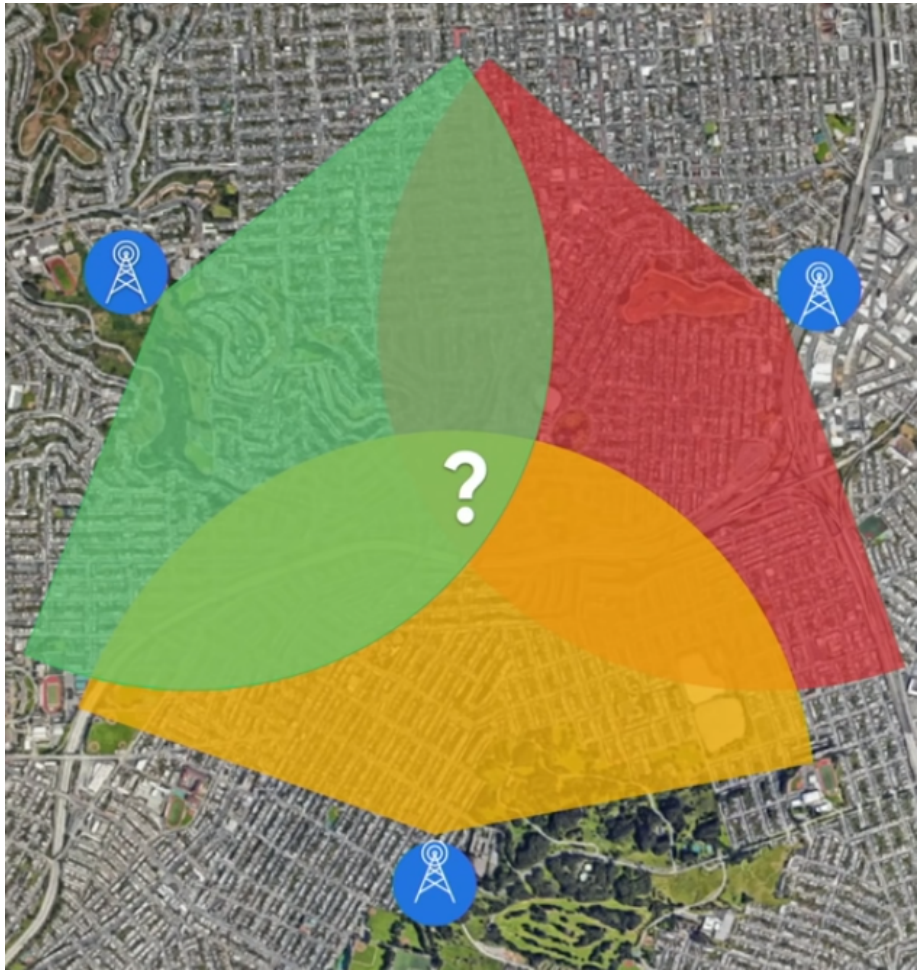

Um método de localização com aprendizado de máquina

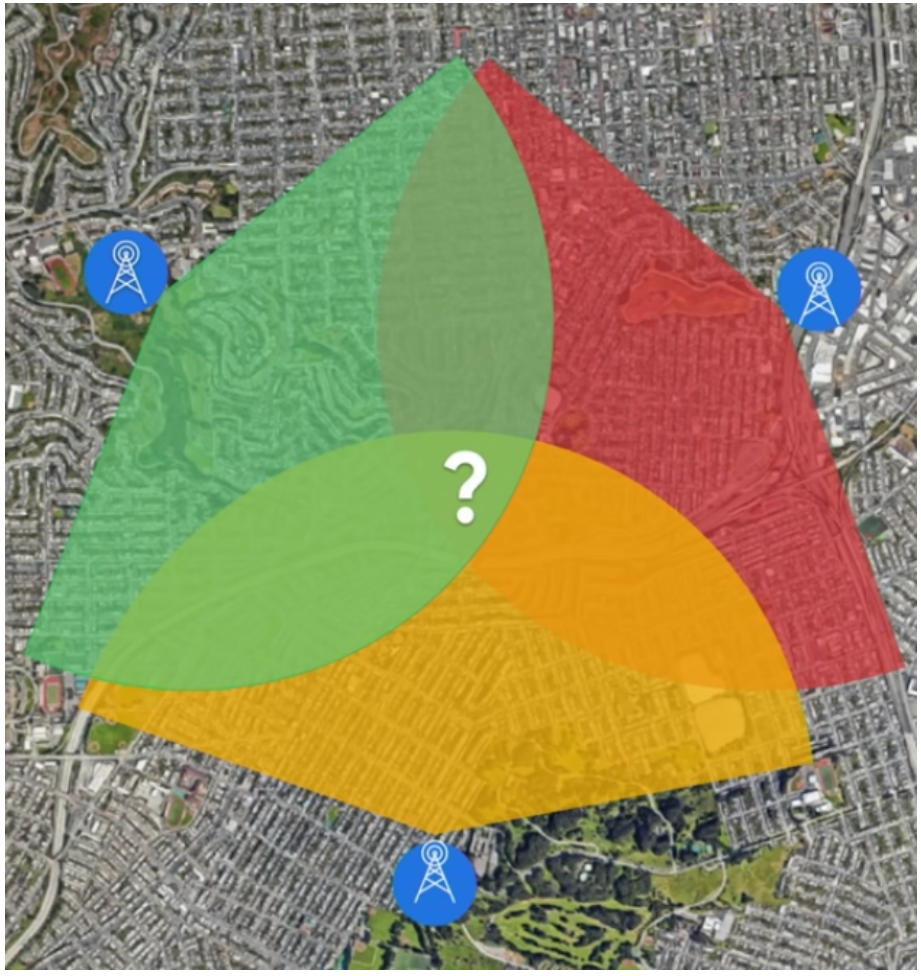

- Estimar a posição da EM com os RSSIs medidos a partir de três ERBs;

Um método de localização com aprendizado de máquina

- Estimar a posição da EM com os RSSIs medidos a partir de três ERBs;

- Implementação de um método de localização baseado em *fingerprinting* usando SVR;

Um método de localização com aprendizado de máquina

- Estimar a posição da EM com os RSSIs medidos a partir de três ERBs;

- Implementação de um método de localização baseado em *fingerprinting* usando SVR;
- Para efeitos de comparação o mesmo método baseado em *fingerprinting* também será usado com COST-231 e ECC-33.

Um método de localização com aprendizado de máquina

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;
  2. Treinar os algoritmos SVR para predição da perda de espaço livre (um para cada ERB);

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;
  2. Treinar os algoritmos SVR para predição da perda de espaço livre (um para cada ERB);
  3. Gerar os mapas de cobertura (um para cada ERB);

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;
  2. Treinar os algoritmos SVR para predição da perda de espaço livre (um para cada ERB);
  3. Gerar os mapas de cobertura (um para cada ERB);
  4. Coletar medições de RSSI da EM procurada nas três ERBs;

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;
  2. Treinar os algoritmos SVR para predição da perda de espaço livre (um para cada ERB);
  3. Gerar os mapas de cobertura (um para cada ERB);
  4. Coletar medições de RSSI da EM procurada nas três ERBs;
  5. Aplicar o filtro de redução do espaço de busca;

Um método de localização com aprendizado de máquina

- **Algoritmo**: Detalhamento do método de localização proposto:
  1. Coletar as medições de RSSI do *scanner* de RF;
  2. Treinar os algoritmos SVR para predição da perda de espaço livre (um para cada ERB);
  3. Gerar os mapas de cobertura (um para cada ERB);
  4. Coletar medições de RSSI da EM procurada nas três ERBs;
  5. Aplicar o filtro de redução do espaço de busca;
  6. Encontrar o ponto mais próximo no mapa de cobertura.

Um método de localização com aprendizado de máquina

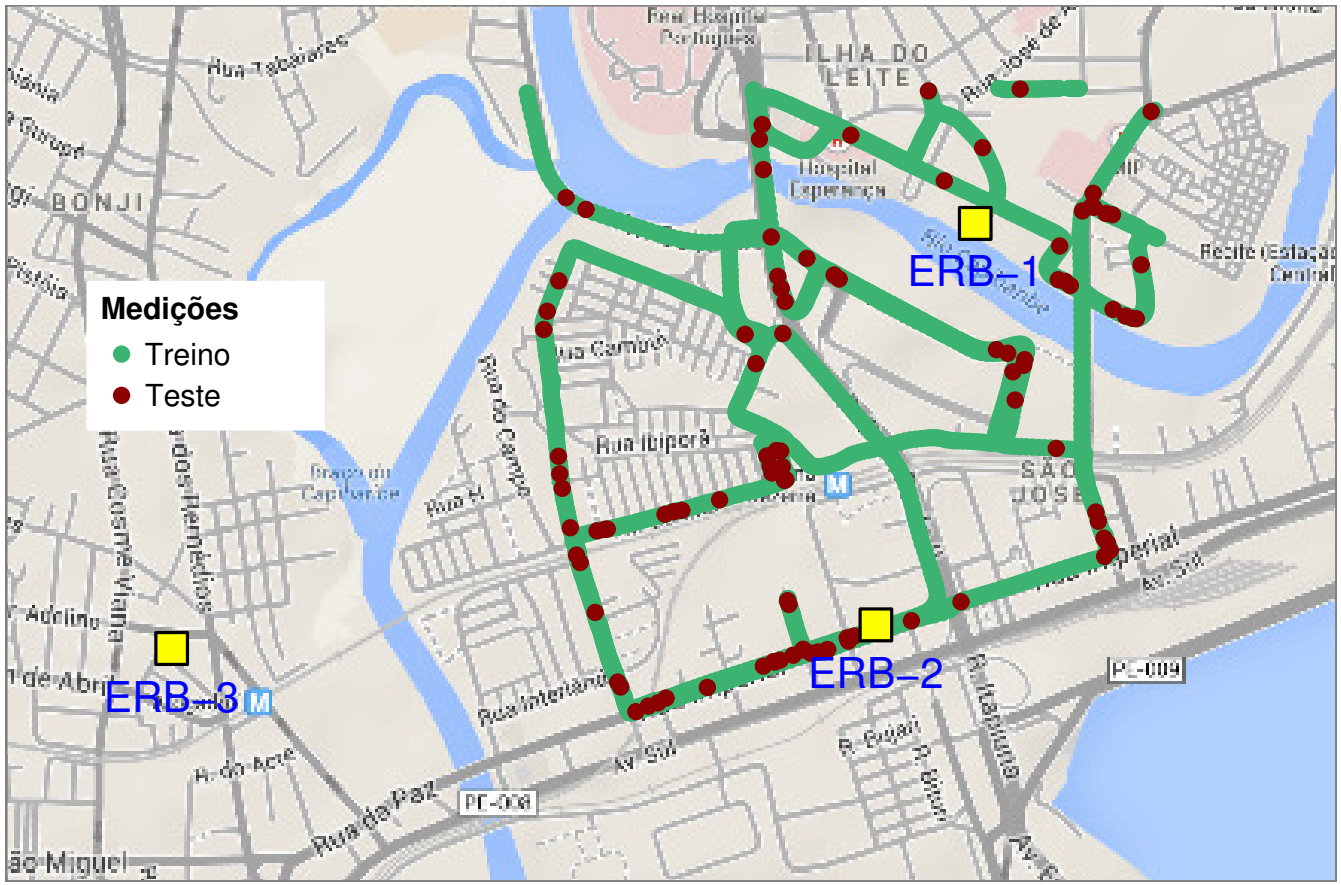

Figura: Ambiente urbano na cidade de Recife-PE com a indicação das medições de teste, de treino e a localização das ERBs.

Um método de localização com aprendizado de máquina

Tabela: Resultados da fase de treinamento de cada algoritmo SVR-Laplaciano usando técnica 10-*fold cross-validation.*

ERB	σ	C	ε	$\bar{\mu}(\mathrm{dB})$	$\mu_\sigma(\mathrm{dB})$
ERB-1	0,258	16	0,1	3,66	0,271
ERB-2	0,207	32	0,1	3,83	0,240
ERB-3	0,215	16	0,1	3,49	0,259

Um método de localização com aprendizado de máquina

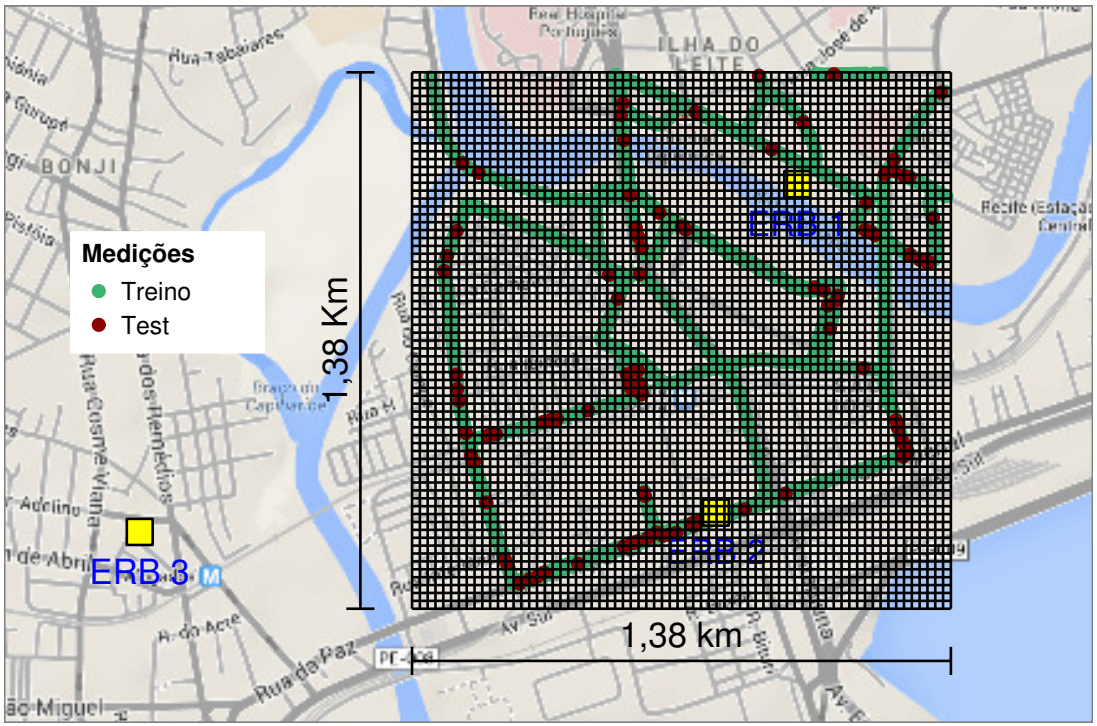

Figura: Área de localização de 1,38 km $\times$ 1,38 km com um grid de resolução de 20 m $\times$ 20 m.

Um método de localização com aprendizado de máquina

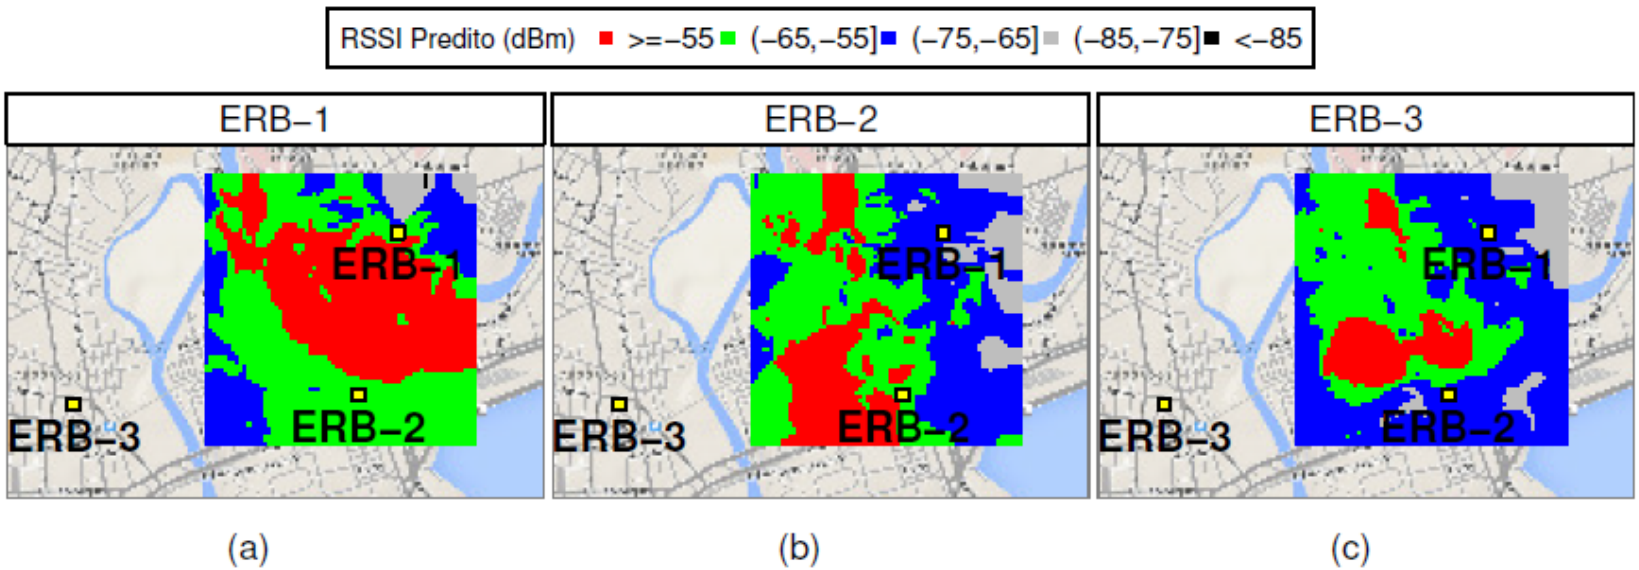

Figura: Mapas de cobertura obtidos a partir das predições de RSSI dos algoritmos SVR para cada ERB:(a) ERB-1. (b) ERB-2. (c) ERB-3.

Um método de localização com aprendizado de máquina

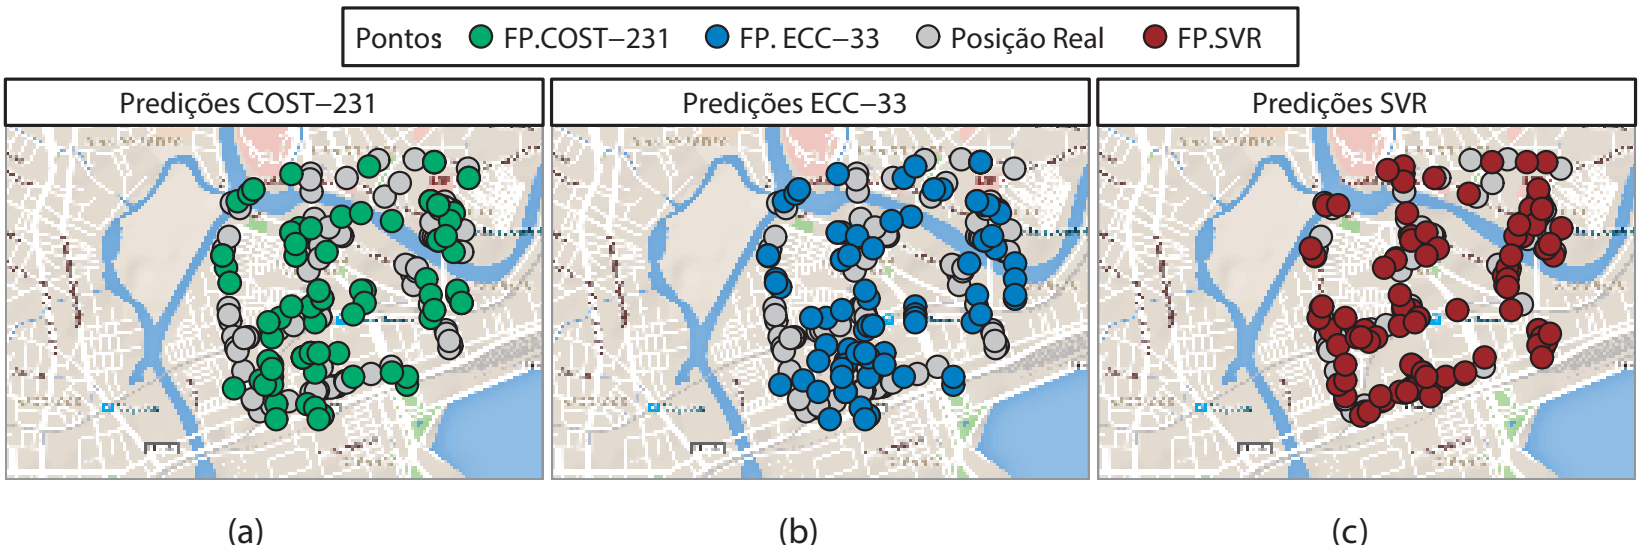

Figura: Mapas de predição para cada método de localização:(a) *Fingerprinting* com COST-231. (b) *Fingerprinting* com ECC-33. (c) Método proposto (algoritmo SVR).

Um método de localização com aprendizado de máquina

Tabela: Análise estatística do erro médio da posição para os três métodos de localização.

Método Loc.	$\bar{\eta}$	η_σ	η_{max}	η_{min}
SVR	54,0 m	56,8 m	383,3 m	0,4 m
FP-COST-231	211,9 m	142,1 m	807,9 m	16,2 m
FP- ECC-33	226,3 m	150,1 m	807,9 m	16,2 m

Um método de localização com aprendizado de máquina

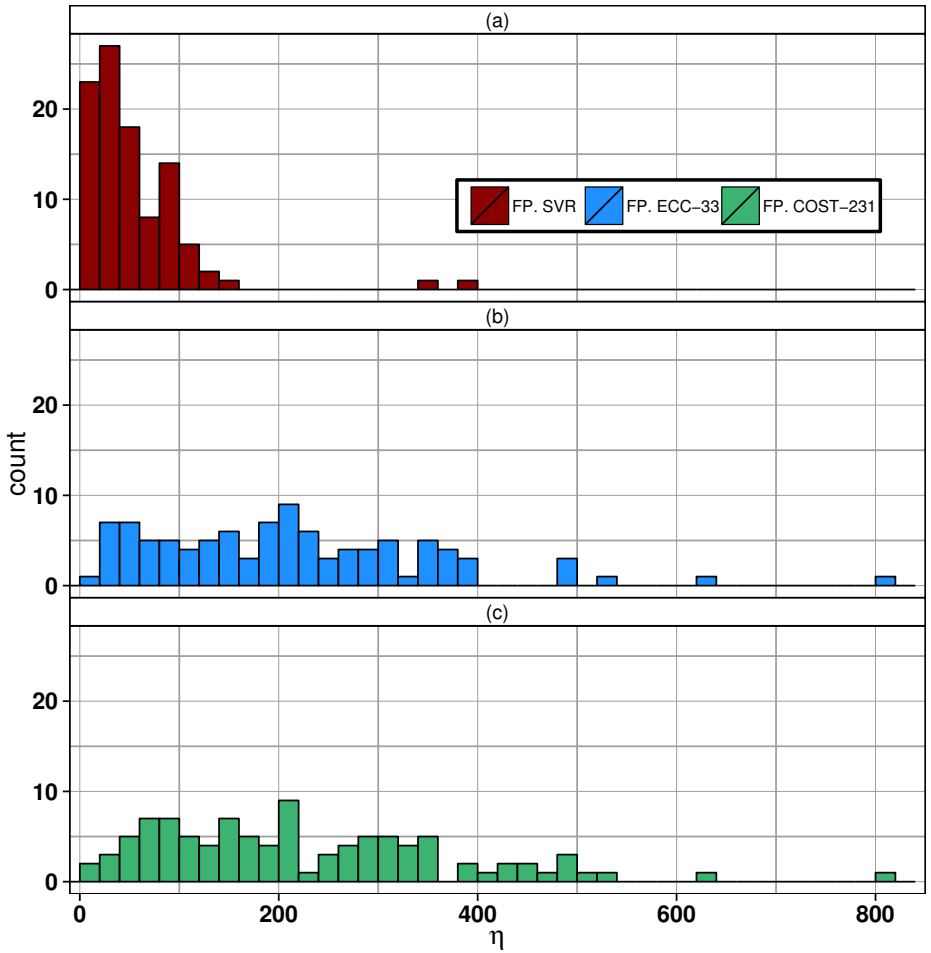

Figura: Histograma do erro médio de localização: (a) SVR. (b) ECC-33. (c) COST-231.

Sumário

1 Apresentação

2 Objetivos

3 Introdução

4 Revisitando técnicas e tecnologias de localização

5 Conceitos básicos aprendizado de máquina

6 Aprendizado de Máquina aplicado às técnicas de localização

7 Oportunidades e desafios

Introdução

- Inúmeras as possibilidades para aplicação de técnicas de aprendizado de máquina em ambientes sem fio.

Introdução

- Inúmeras as possibilidades para aplicação de técnicas de aprendizado de máquina em ambientes sem fio.

Figura: Aplicação *Android Emergency Location Service- Locating Emergency Calls in a Wireless World (https://www.youtube.com/watch?v=8HvOGXld-2At=687s).*

Introdução

- Como fazer a melhor escolha entre as técnicas?

Introdução

- Como fazer a melhor escolha entre as técnicas?
- Como aliar acurácia e desempenho?

Introdução

- Como fazer a melhor escolha entre as técnicas?
- Como aliar acurácia e desempenho?

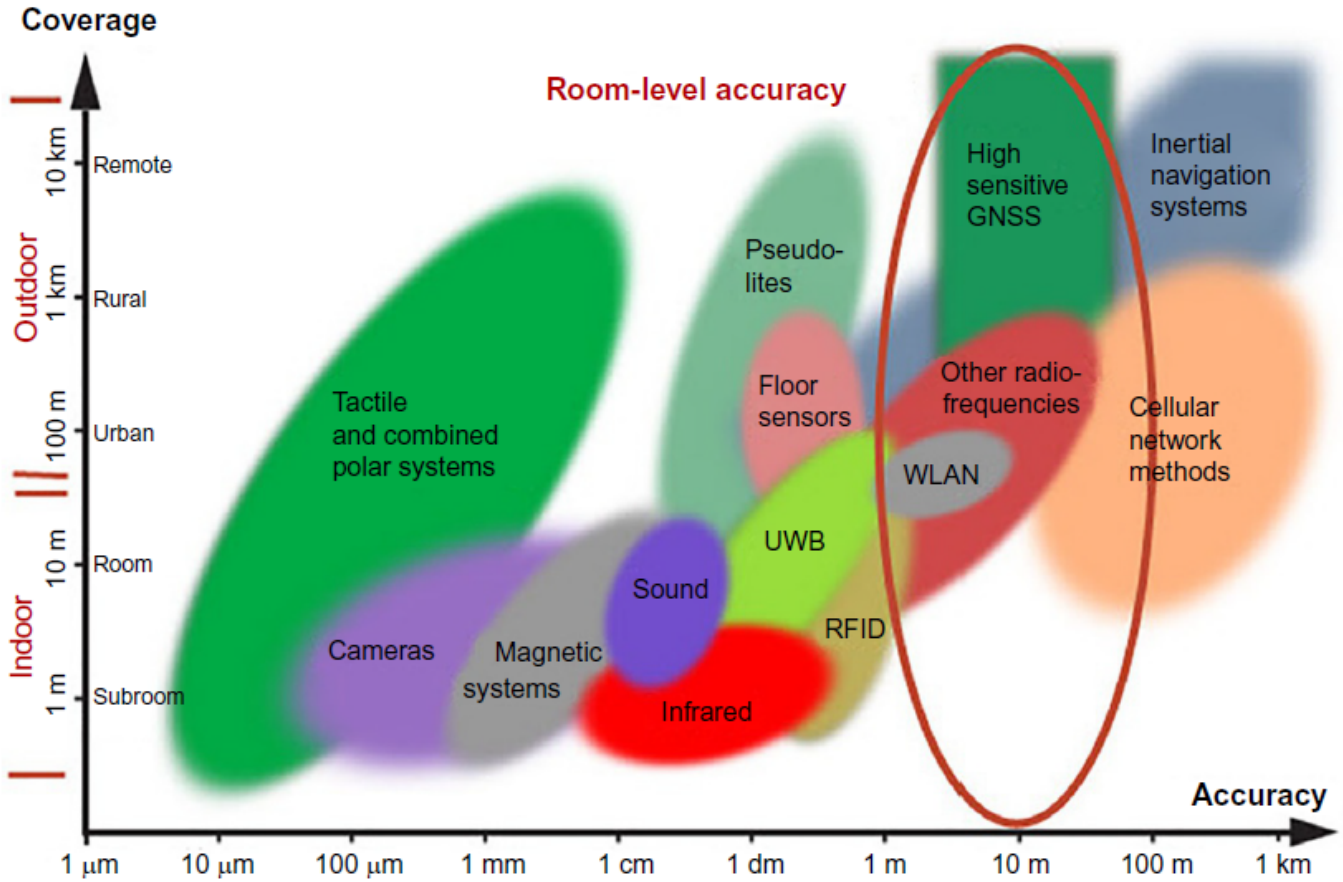

Vertentes de Pesquisa

- FS-KNN (*(Feature scaling k-NN)*: Pesos diferentes para os valores de RSSI;

Vertentes de Pesquisa

- FS-KNN (*(Feature scaling k-NN)*: Pesos diferentes para os valores de RSSI;
- OISVM (*Online independent SVM*): Aprendizado dinâmico.
  - Redução da Complexidade computacional;
  - Melhoria da acurácia.

Vertentes de Pesquisa

- FS-KNN (*(Feature scaling k-NN)*: Pesos diferentes para os valores de RSSI;
- OISVM (*Online independent SVM*): Aprendizado dinâmico.
  - Redução da Complexidade computacional;
  - Melhoria da acurácia.
- RVM (*Relevance vector machine*): Vem sendo utilizado com sucesso para diferenciar *LoS* e *NLoS*.
  - Usa menos vetores de suporte.

Vertentes de Pesquisa

- FS-KNN (*(Feature scaling k-NN)*: Pesos diferentes para os valores de RSSI;
- OISVM (*Online independent SVM*): Aprendizado dinâmico.
  - Redução da Complexidade computacional;
  - Melhoria da acurácia.
- RVM (*Relevance vector machine*): Vem sendo utilizado com sucesso para diferenciar *LoS* e *NLoS*.
  - Usa menos vetores de suporte.
- Melhoria da geometria do *grid*: Mapas de rádio;

Vertentes de Pesquisa

- FS-KNN (*(Feature scaling k-NN)*: Pesos diferentes para os valores de RSSI;
- OISVM (*Online independent SVM*): Aprendizado dinâmico.
  - Redução da Complexidade computacional;
  - Melhoria da acurácia.
- RVM (*Relevance vector machine*): Vem sendo utilizado com sucesso para diferenciar *LoS* e *NLoS*.
  - Usa menos vetores de suporte.
- Melhoria da geometria do *grid*: Mapas de rádio;
- Plataformas **Big Data**:
  - *Apache Spark* e *H20* para uso com *Deep Learning*;
  - *Crowdsourcing*: Coletas pontos em toda a rede celular.

Não para por aqui!

Contato

Lizandro Silva

lizandro.silva@recife.ifpe.edu.br

Agradecimentos

Obrigado!