

Inteligência Artificial e Cibersegurança

Outubro—Mês Europeu da Cibersegurança

Diogo Nuno Freitas
diogo.freitas@iti.larsys.pt

Ciclo de Conversas *online* com quem sabe.

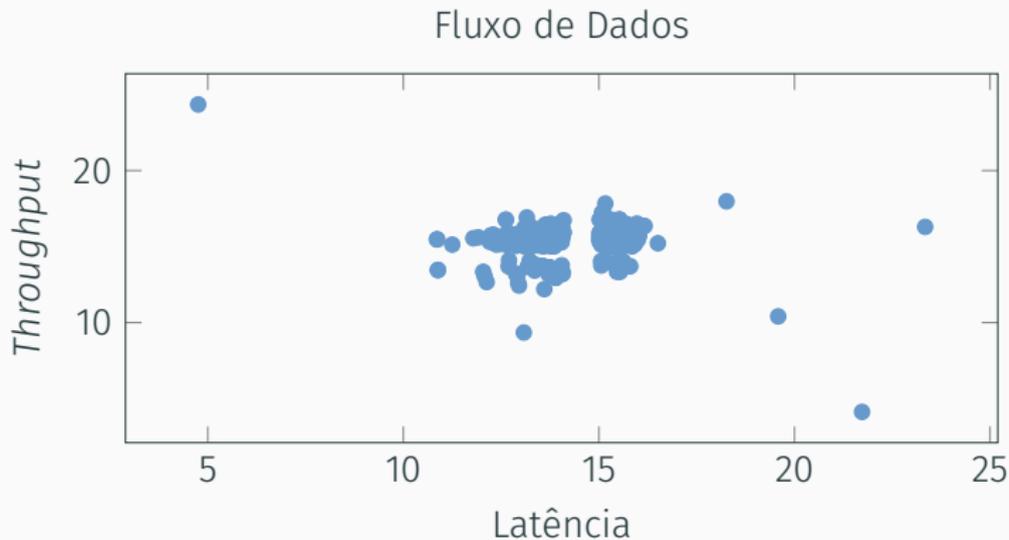
1 de novembro de 2021



Motivação

Motivação

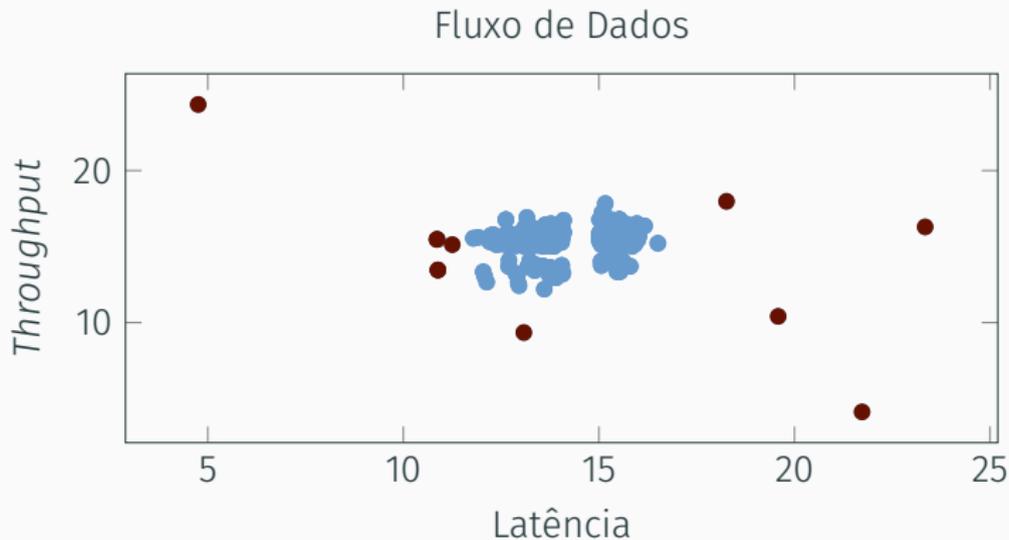
Olhando para este gráfico, quais os pontos que nos **chamam mais a atenção**?



Como pode um sistema detectar automaticamente esses pontos?

Motivação

Olhando para este gráfico, quais os pontos que nos chamam mais a atenção?



Como pode um sistema detectar automaticamente esses pontos?

Podemos começar por calcular a **média** e o **desvio padrão**, isto é,

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \approx 14,42 \quad \text{e} \quad \sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \approx 1,45.$$

Vamos usar essas duas medidas para calcular o **limite** (l) para os dados considerados *normais*:

$$l = \sigma \times c,$$

onde c é uma constante arbitrária.

Finalmente, podemos definir os limites **inferiores e superiores**, de tal forma que:

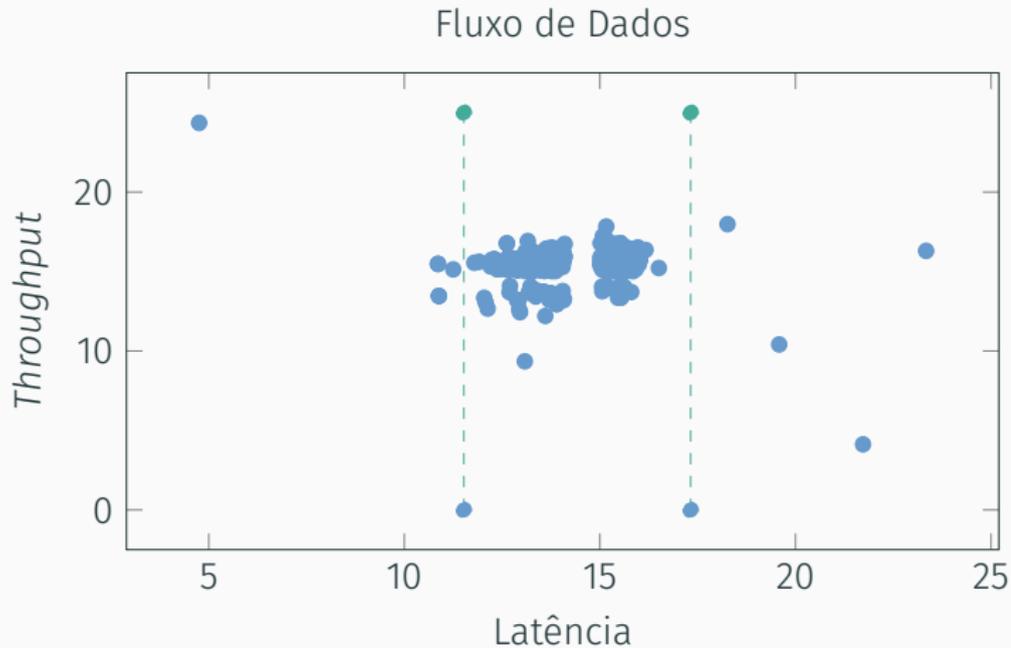
$$\begin{cases} l_{\text{inf}} = \bar{x} - l, \\ l_{\text{sup}} = \bar{x} + l. \end{cases}$$

Ou seja, um **ponto é considerado *normal*** se $l_{\text{inf}} \leq x_i \leq l_{\text{sup}}$.

Para o nosso caso, e considerando $c = 2$,

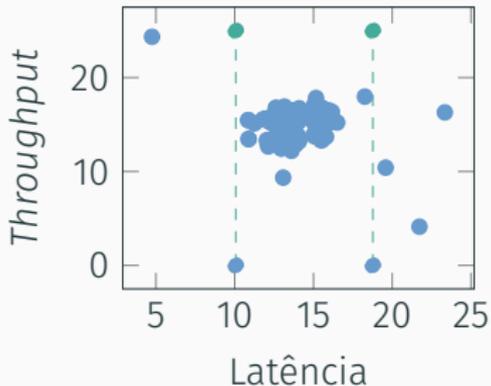
$$\begin{cases} l_{\text{inf}} = 14,42 - 2,90 \approx 11,52, \\ l_{\text{sup}} = 14,42 + 2,90 \approx 17,32. \end{cases}$$

Graficamente, estamos a **criar duas rectas verticais**, tais como,

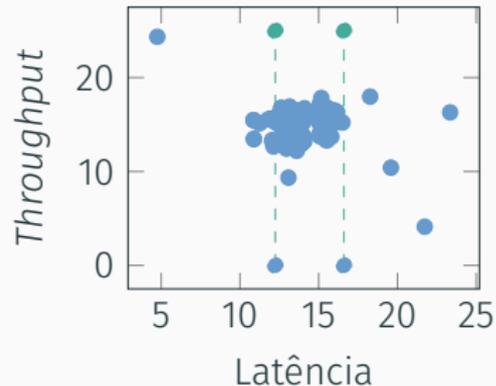


Como definir c ?

Fluxo de Dados ($c = 3$)



Fluxo de Dados ($c = 1,5$)



Motivação: Como definir o valor de c ?

Precisamos de uma forma automática (e adaptativa) para classificar os pontos como sendo *normais* ou *outliers* → **Inteligência Artificial.**

Objectivos da sessão

Objectivos da sessão

1. Perceber a motivação para o uso de **métodos automáticos de classificação**.
2. Ter uma percepção breve sobre a **história da Inteligência Artificial (IA)**.
3. Introduzir **conceitos básicos** de *machine learning* (ML).
4. Conhecer os **modelos de IA utilizados actualmente**.
5. Perceber como é que esses modelos podem ser **aplicados no âmbito da cibersegurança**.

Introdução

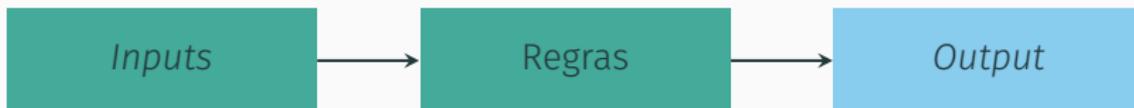
Introdução

O que é a IA?

É uma **invenção humana** que permite usar sistemas informáticos para **simular comportamentos humanos inteligentes**.

Com a IA, assistimos a uma **mudança no paradigma de programação** que até então estávamos habituados.

Programação tradicional:



Machine Learning:



Acontecimentos importantes:

- Em 1943, **McCulloch e Pitts** desenvolveram o **primeiro modelo computacional inteligente**: uma rede neuronal artificial.
- Rosenblatt nos finais da década de 50 e começo da década de 60, sugere **perceptrões**.
- Linnainmaa sugere o algoritmo de *backpropagation* (1970).
- Em 1979, Fukushima propõe as **rede neuronais convolucionais (CNN)**.

Outros acontecimentos importantes:

- As redes *long short-term memory (LSTM)* são sugeridas em 1997.
- Na década de 2000, começam a surgir implementações dos **algoritmos de treino em GPUs**.
- Goodfellow e colaboradores introduzem as redes ***Generative Adversarial*** em 2014.
- Recentemente, o conceito de ***transformers*** foi introduzido para processamento de linguagem natural.

Já existem diversas aplicações de modelos de IA à cibersegurança. E existirão cada vez mais!

Vantagens:

- Possibilita **detectar padrões** em milhões tuplos de dados.
- Permite fazer **processamento de linguagem natural**.
- Possibilita executar aplicações que estão sempre **atentas**.
- Garante que os modelos **aprendam constantemente com novas informações**.

Existem, contudo, algumas dificuldades que estão **dependentes dos humanos**.

Dificuldades:

- **Elevado desequilíbrio** entre o número de dados de ameaças e os de não-ameaça.
- O **sucesso dos modelos está sempre dependente da disponibilização de informação**.
- **Falta de recursos humanos** qualificados na área de IA.
- **Custos elevados** com formação e com equipamentos.
- Pode acontecer virar-se o **feitiço contra o feiticeiro!**

Conceitos básicos

O que são *features*?

Features ou *atributos* são propriedades que **descrevem uma possível relação com a variável de saída**. Os atributos podem ser numéricos ou categóricos.

Criação de *features*

Métodos manuais ou automáticos de **criação de novos atributos com base nos que já existem**.

Seleção de *features*

Métodos manuais ou automáticos para **reduzir a dimensionalidade do problema**.

Quais são os dois tipos de problemas mais comuns para ML?

Classificação

Os modelos utilizam os atributos fornecidos para **categorizar os dados em classes**. Maioritariamente associada com tarefas de *clustering*.

Regressão

Os modelos tentam **inferir uma função real** para mapear os atributos e as variáveis de saída (em valor real).

Quais são os dois tipos de aprendizagem mais comuns para ML?

Supervised learning

Quando disponibilizamos ao modelo **exemplos de mapeamento** entre as entradas (atributos) e as saídas.

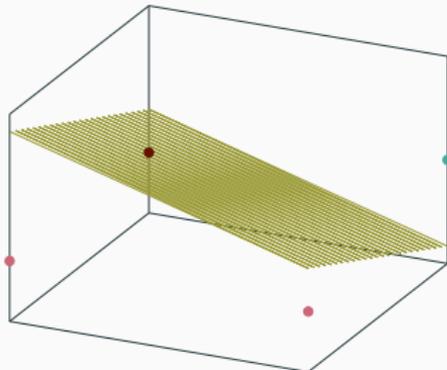
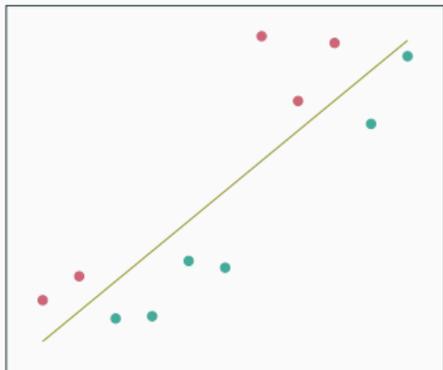
Unsupervised learning

No caso do *unsupervised learning*, esse mapeamento **não é fornecido à rede**. A rede é, assim, obrigada a **aprender a classificar os dados com base nos padrões ou nos *clusters*** que encontrar.

Exemplos práticos

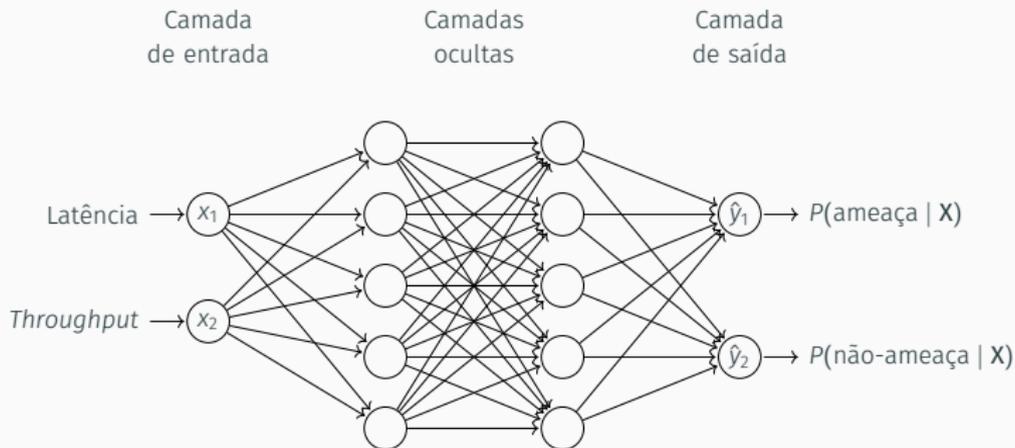
Objectivo de modelo

Na sua essência, o faz um modelo de ML?



Num problema de classificação, tenta encontrar **uma linha ou um plano que permita separar as classes.**

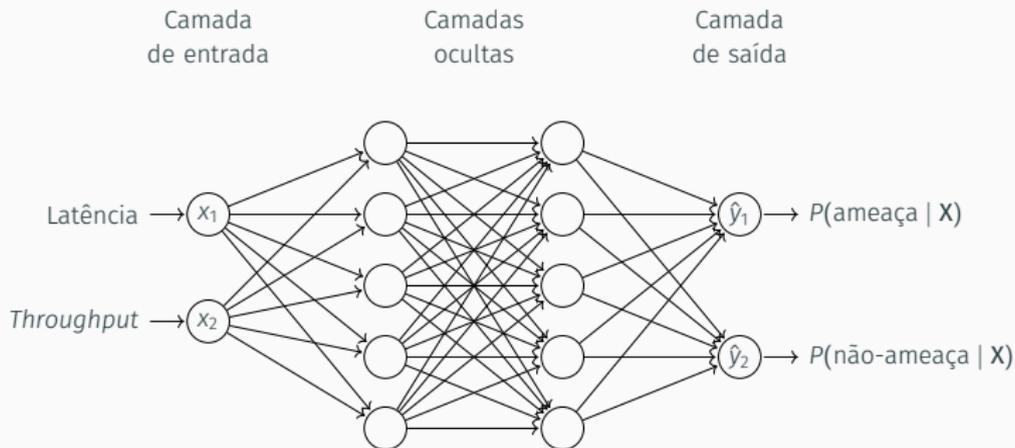
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

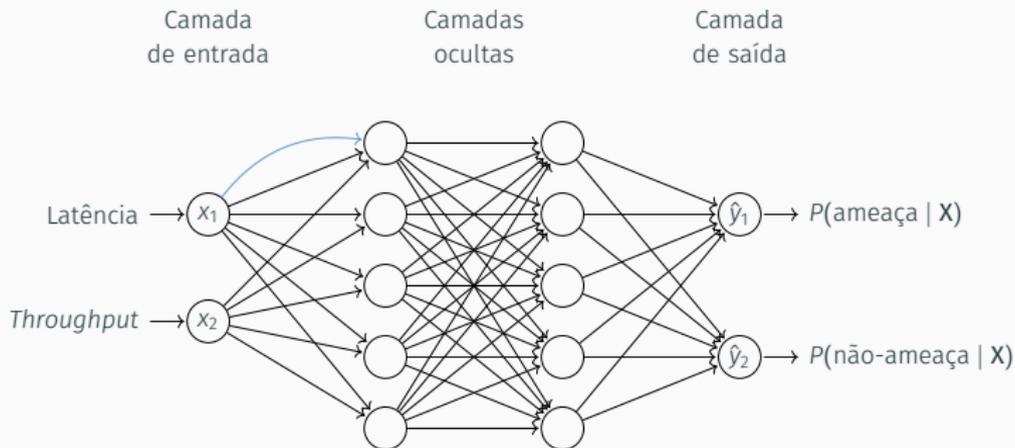
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

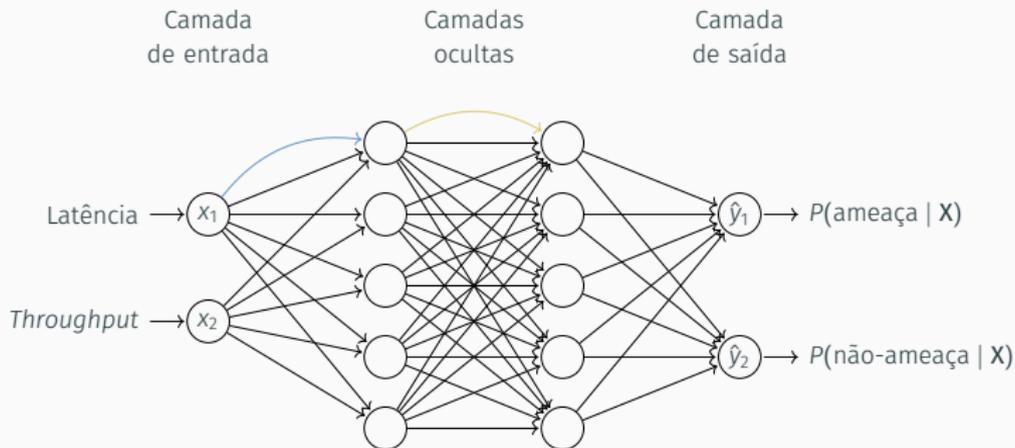
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

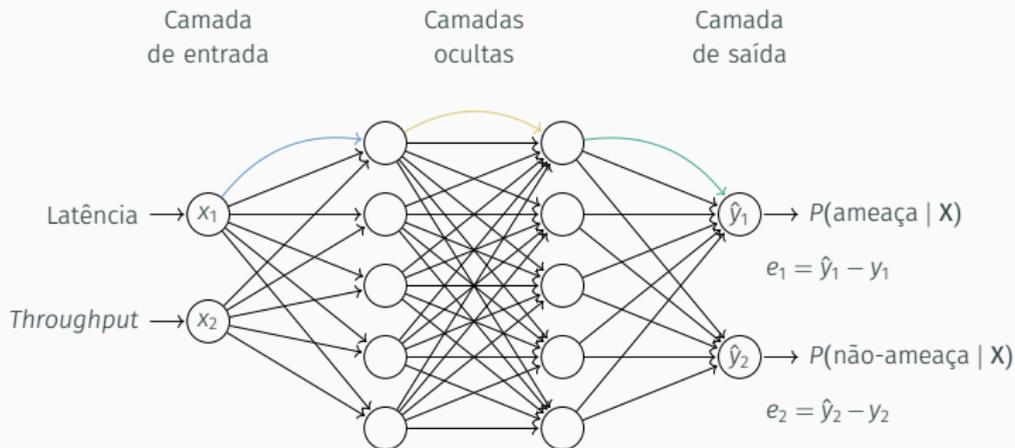
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

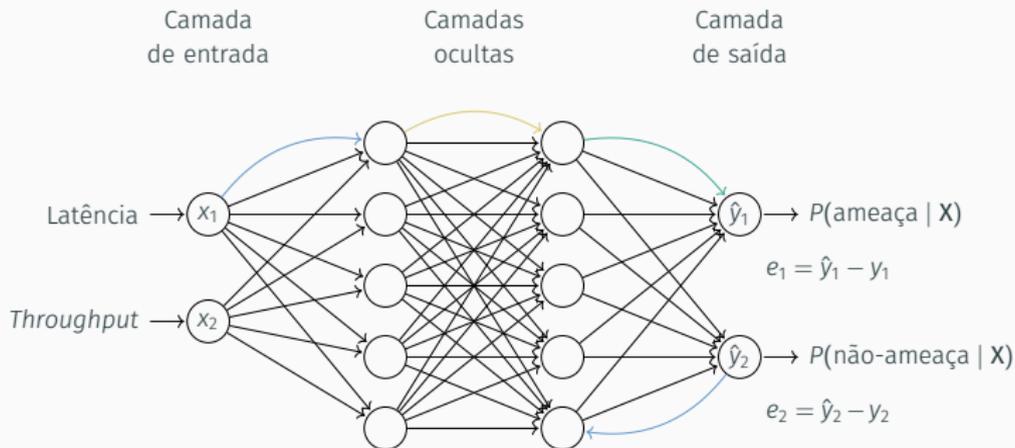
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

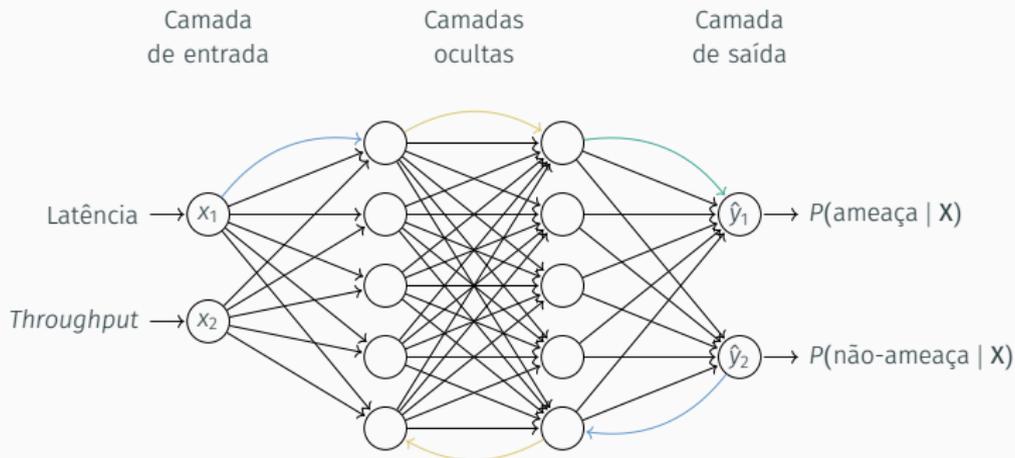
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

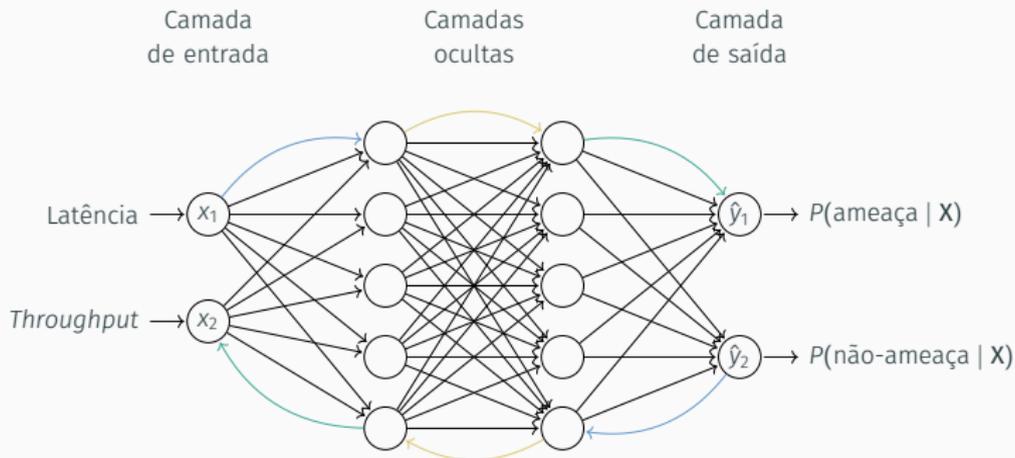
Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

Exemplo 1: Redes Neurais Artificiais



Numa rede neuronal artificial (RNA), existem duas passagens:

- *Forward Propagation.*
- *Backward Propagation.*

Os neurónios numa RNA têm duas funções:

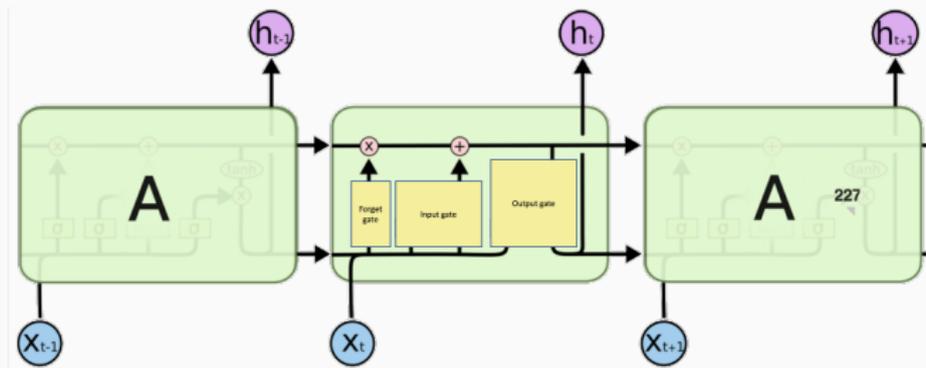
- Função de transferência ($T = W \cdot I$);
- Função de activação (ϕ).

O algoritmo de *backpropagation* consiste em dois aspectos fundamentais:

- Cálculo do erro de saída e retropropagação até aos neurónios de entrada;
- Actualização dos pesos por meio de um algoritmo de optimização.

Exemplo 2: LSTMs

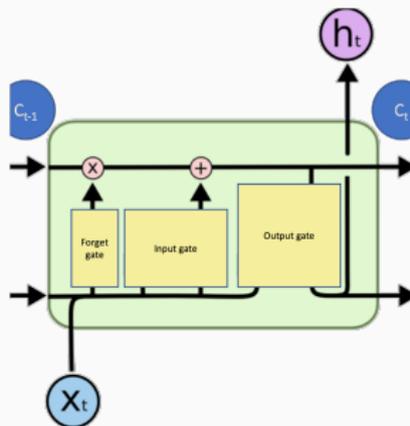
A estrutura de uma rede Long Short Term Memory (LSTM) é a seguinte¹:



As LSTMs são modelos úteis quando existe uma **sequência ordenada nos dados**, pois conseguem guardar **contexto**.

¹Imagem adaptada de: <https://colah.github.io/posts/2015-08-Understanding-LSTMs>

Exemplo 2: LSTMs (cont.)



Cada célula de uma LSTM possui três operações/portas (*gates*):

- *forget*—que informação esquecer?
- *input*—o que adicionar ao que já sei?
- *output*—que informação passar?

Exemplo 2: LSTMs (cont.)

Este tipo de redes consegue aprender **dependências douradoras, bem como esporádicas.**

No âmbito da cibersegurança, as LSTMs podem ser usadas **para detectar e prevenir fraudes.** Vejamos um exemplo.

t	x	y
1	15	0
2	45	0
3	65	0
4	500	1
5	500	1
6	25	0

Exemplo 2: LSTMs (cont.)

Para dar contexto à LSTM, os dados **precisam de reestruturados em janela deslizante**. Neste caso, o tamanho da janela escolhido foi 3.

x_1	x_2	x_3	y
15	45	65	0
45	65	500	0
65	500	500	1
500	500	25	1

Iremos ter uma LSTM **com três células para prever** y , e detectar movimentos potencialmente fraudulentos.

Exemplo 3: SVMs e NLP

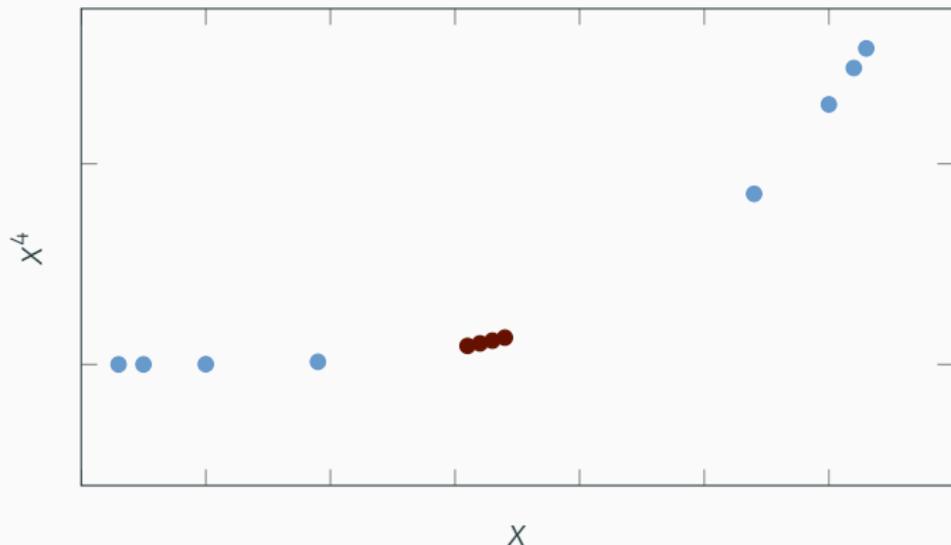
O último exemplo que vamos ver usa as **Support Vector Machines (SVMs)** e o **Processamento de Linguagem Natural (NLP)**.

Começemos por entender como é que as SVMs funcionam.

Como podemos separar as seguintes classes?

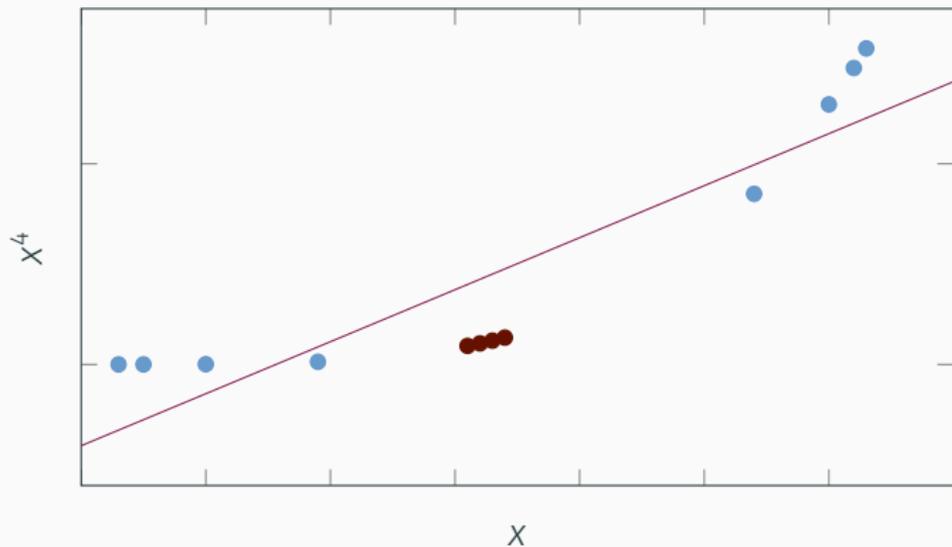


Exemplo 3: SVMs e NLP (cont.)



As SVMs na sua essência encontram um **hiperplano** capaz de separar as duas classes.

Exemplo 3: SVMs e NLP (cont.)



As SVMs na sua essência encontram um **hiperplano** capaz de separar as duas classes.

Como podemos desenvolver um sistema automático para detectar se um e-mail é *SPAM*, ou não?

Abordagem n -grama

Permite separar o texto em sequências de n caracteres ou palavras.

Modelo *bag-of-words*

Permite transformar a linguagem natural em representação numérica. A representação numérica é feita à custa da frequência de cada termo.

A partir daqui, passamos a ter um problema comum de ML que podemos resolver usando as SVMs.

Conclusão

Conclusão

Começamos por ver **como podemos classificar manualmente** acontecimentos anormais.

Percebemos **como surgiram os primeiros modelos de ML**.

Entendemos o que são **atributos**, quais os **problemas mais comuns** e que **tipos de aprendizagem existem**.

Finalmente, **aplicamos três modelos de ML** a problemas de cibersegurança.

ANN

Tipos de problema	Classificação e regressão.
Tipos de aprendizagem	<i>Supervised.</i>
Dados	Qualquer tipo de dados.
Exemplos de aplicação	Dados não ordenados (geral).

LSTM

Tipos de problema	Classificação e regressão.
Tipos de aprendizagem	<i>Supervised.</i>
Dados	Bases de dados com muitos registos.
Exemplos de aplicação	Previsão (séries ordenadas).

	SVM
Tipos de problema	Classificação e regressão.
Tipos de aprendizagem	<i>Supervised.</i>
Dados	Dados de grandes dimensões.
Exemplos de aplicação	NLP.

- [1] S. Aiyar and N. P. Shetty.
N-gram assisted youtube spam comment detection.
Procedia Computer Science, 132:174–182, 2018.
International Conference on Computational Intelligence and Data Science.
- [2] A. Parisi.
Hands-On Artificial Intelligence for Cybersecurity: Implement Smart AI Systems for Preventing Cyber Attacks and detecting threats and network anomalies.
Packt Publishing, 2019.
- [3] C. Sammut and G. Webb.
Encyclopedia of Machine Learning.
Encyclopedia of Machine Learning. Springer US, 2011.

[4] E. Tsukerman.

Machine Learning for Cybersecurity Cookbook: Over 80 Recipes on How to Implement Machine Learning Algorithms for Building Security Systems Using Python.

Packt Publishing, 2019.

Inteligência Artificial e Cibersegurança

Outubro—Mês Europeu da Cibersegurança

Diogo Nuno Freitas
diogo.freitas@iti.larsys.pt

Ciclo de Conversas *online* com quem sabe.

1 de novembro de 2021

