



UNINASSAU

REDES NEURAIS ARTIFICIAIS

Professor: André Guerra



Treinamento de Redes Neurais

Objetivo da Aula:

Estudar as Redes de Kohonen



Introdução às redes de Kohonen

Definição e Origem das Redes de Kohonen

- As redes de Kohonen, também conhecidas como **Mapas Auto-Organizáveis** (*Self-Organizing Maps* ou SOM), foram desenvolvidas pelo neurocientista finlandês **Teuvo Kohonen** em 1982.
- Elas pertencem à classe de redes neurais **não supervisionadas**, ou seja, são capazes de aprender padrões nos dados sem a necessidade de rótulos (informações pré-definidas sobre os dados de entrada).
- O objetivo principal de um SOM é **reduzir a dimensionalidade** dos dados enquanto preserva as relações topológicas entre eles.



Conceitos básicos

- As redes de Kohonen são redes neurais que utilizam um algoritmo de aprendizado competitivo para **mapear dados multidimensionais em uma grade de neurônios de menor dimensão** (geralmente uma grade 2D).
- O mapa resultante organiza-se de maneira que **neurônios vizinhos respondem de forma semelhante a padrões de entrada similares**, criando uma visualização espacial dos dados.



Estrutura básica

- A rede de Kohonen é composta de uma **camada única de neurônios**, organizados em uma grade bidimensional.
- Cada neurônio no mapa está associado a um **vetor de pesos**, que representa uma posição no espaço de entrada.
- Durante o processo de aprendizado, esses vetores de peso se ajustam para se tornarem **representações fiéis dos dados** de entrada.



Comparação com outras redes neurais

- **Redes supervisionadas** (como as redes feedforward) aprendem ajustando seus pesos com base em um conjunto de dados rotulados, minimizando o erro entre a saída prevista e a saída real.
- Já as **redes não supervisionadas** (como as SOMs) detectam automaticamente padrões e agrupamentos nos dados sem a necessidade de rótulos.
- Um **exemplo clássico de rede não supervisionada** são os algoritmos de clustering, como o **K-Means**, mas a principal diferença é que as SOMs preservam a **estrutura topológica** dos dados.



Aplicações típicas de redes de Kohonen

- **Segmentação de clientes:** As redes de Kohonen podem agrupar clientes com características semelhantes, útil em marketing.
- **Visualização de dados:** Ao reduzir a dimensionalidade, podemos ver padrões em dados complexos que seriam difíceis de detectar diretamente.
- **Reconhecimento de padrões:** Em campos como biologia e medicina, as SOMs podem ajudar a identificar padrões em dados genômicos ou sinais de eletroencefalograma (EEG).

Estrutura da rede de Kohonen

Arquitetura da Rede

- A rede de Kohonen é composta por **uma única camada de neurônios**, que formam uma **grade (lattice)**, geralmente bidimensional.
- Cada neurônio nessa grade está associado a um **vetor de pesos** $W = [w_1, w_2, \dots, w_n]$, onde n é o número de dimensões do espaço de entrada (ou seja, o número de características ou variáveis dos dados de entrada).



Estrutura da rede de Kohonen


Organização dos Neurônios

- Topologia da Grade:
 - A grade de neurônios pode ser organizada de várias formas. As configurações mais comuns são:
 - **Grade quadrada:** Onde os neurônios são dispostos em linhas e colunas, formando uma malha quadrada.
 - **Grade hexagonal:** Onde os neurônios são dispostos de forma que cada neurônio tenha seis vizinhos diretos. Essa configuração é preferida em muitas aplicações devido à melhor preservação da topologia.
- Cada neurônio é conectado a todos os **neurônios vizinhos** em uma certa distância, o que facilita o aprendizado cooperativo entre eles.


Estrutura da rede de Kohonen



UNINASSAU



(a)



(b)

a) Grade hexagonal

b) Grade quadrada



Estrutura da rede de Kohonen

. Vetores de Peso Associados aos Neurônios

- Cada neurônio em uma rede de Kohonen é representado por um **vetor de pesos** W_j , onde j denota o índice do neurônio na grade.
- Os **vetores de peso** podem ser vistos como "protótipos" dos dados de entrada que o neurônio deverá "aprender". O vetor de peso W_j será atualizado durante o processo de treinamento para se aproximar dos vetores de entrada mais próximos a ele no espaço de características.



Estrutura da rede de Kohonen

Mapeamento do Espaço Multidimensional para a Grade 2D

- A **entrada da rede** é um vetor de dimensão n , representando as características dos dados de entrada.
- A rede mapeia o espaço multidimensional dos dados de entrada para uma **grade bidimensional**, preservando as relações de similaridade entre os dados. Dados semelhantes estarão próximos na grade final da rede de Kohonen.
- **Preservação de topologia:** O SOM organiza os dados de maneira que a **similaridade entre os dados de entrada** seja refletida na proximidade dos neurônios no mapa. Ou seja, neurônios vizinhos no mapa terão pesos semelhantes, correspondendo a dados de entrada semelhantes.

Estrutura da rede de Kohonen

. Atualização Cooperativa entre Neurônios

- Quando um neurônio é **ativado** (ou seja, é considerado o "vencedor" no processo de aprendizado), ele não ajusta seus pesos isoladamente. Em vez disso, **os neurônios vizinhos** ao vencedor também atualizam seus pesos em menor grau, formando o chamado **campo de vizinhança**.
- O **campo de vizinhança** é maior no início do processo de aprendizado e vai diminuindo à medida que o treinamento avança, garantindo uma **auto-organização global** no início e uma **fina adaptação local** ao final.



Topologia de rede e funções de vizinhança



Topologia da Rede e Funções de Vizinhança

- O conceito de **função de vizinhança** é crucial no SOM, pois define como os neurônios "colaboram" no processo de treinamento. Quando um neurônio ganha a competição (é o "vencedor"), seus vizinhos também atualizam seus pesos, mas em menor intensidade.
- Existem várias funções de vizinhança, mas a mais comum é a **função gaussiana**, onde o grau de atualização decai exponencialmente com a distância ao neurônio vencedor:

$$h(i, j, t) = \exp \left(\frac{-d(i, j)^2}{2\sigma(t)^2} \right)$$

Onde $h(i, j, t)$ é o fator de vizinhança, $d(i, j)$ é a distância entre o neurônio vencedor i e o neurônio j , e $\sigma(t)$ é o raio de vizinhança que diminui com o tempo.


Arquitetura da redes de Kohonen



Arquitetura da redes de Kohonen



UNINASSAU



Treinamento da rede de Kohonen

Inicialização

- Antes do treinamento, os **vetores de peso** de cada neurônio são inicializados. A inicialização pode ser:
 - **Aleatória**: Pesos são atribuídos de forma aleatória.
 - **Baseada nos dados**: Pesos podem ser inicializados próximos aos dados de entrada para acelerar a convergência.



Treinamento da rede de Kohonen

. Fase Competitiva

- A cada iteração, um vetor de entrada é apresentado à rede.
- A **competição entre neurônios** ocorre para determinar qual neurônio na rede é mais similar à entrada.
- O neurônio com o vetor de pesos mais próximo ao vetor de entrada é chamado de **neurônio vencedor** ou **BMU (Best Matching Unit)**.
- A métrica de similaridade mais comum é a **distância euclidiana**:

$$D(j) = \|X - W_j\|$$

Onde X é o vetor de entrada e W_j é o vetor de pesos do neurônio j .



Treinamento da rede de Kohonen

. Fase Cooperativa

- O neurônio vencedor não é o único a ser atualizado. Os **neurônios vizinhos** ao vencedor (dentro de uma vizinhança pré-definida) também têm seus pesos ajustados.
- O raio da **vizinhança** diminui com o tempo, começando grande no início do treinamento e diminuindo ao longo das iterações.

Treinamento da rede de Kohonen

Fase Adaptativa

- Durante o treinamento, os pesos do neurônio vencedor e seus vizinhos são atualizados para se aproximarem do vetor de entrada.
- A **taxa de aprendizado** $\alpha(t)$ também diminui ao longo do tempo para garantir que os ajustes sejam mais finos nas últimas etapas do treinamento.



Algoritmo de Kohonen

Passos do Algoritmo de Kohonen

- **Passo 1 - Inicialização:** Inicializar os vetores de pesos dos neurônios.
- **Passo 2 - Apresentar a entrada:** Selecionar aleatoriamente um vetor de entrada do conjunto de dados.
- **Passo 3 - Encontrar o neurônio vencedor:** Calcular a distância entre o vetor de entrada e cada vetor de pesos. O neurônio com a menor distância é o BMU.
- **Passo 4 - Atualização dos pesos:** Atualizar o vetor de pesos do BMU e dos neurônios vizinhos.
- **Passo 5 - Repetição:** Repetir os passos 2-4 para cada vetor de entrada, várias vezes (número de iterações).



Vantagens das redes de Kohonen

- **Simplicidade:** O algoritmo de Kohonen é relativamente simples de entender e implementar.
- **Auto-Organização:** A rede pode aprender padrões sem supervisão.
- **Capacidade de Clustering:** SOMs oferecem uma maneira intuitiva e visual de agrupar dados.
- **Visualização de Dados:** Muito útil para explorar e visualizar dados de alta dimensionalidade em um espaço 2D.
- **Preservação de Topologia:** Diferente de outros métodos de clustering, os SOMs mantêm a proximidade espacial dos dados.



Desvantagens das redes de Kohonen

- **Escolha de Parâmetros:** O desempenho do SOM pode depender fortemente da escolha de parâmetros como a **taxa de aprendizado** e o **tamanho da vizinhança**.
- **Escalabilidade:** Para conjuntos de dados muito grandes, o SOM pode se tornar computacionalmente caro.
- **Risco de Overfitting Local:** A auto-organização pode resultar em uma adaptação excessiva a padrões específicos em vez de padrões globais.
- **Tamanho da Rede:** Definir o número ideal de neurônios na rede pode ser desafiador, uma vez que ele afeta a granularidade da representação dos dados.



UNINASSAU

Demonstração prática



UNINASSAU

Conclusão

Recapitulação dos pontos principais