



# **Classificação de Imagens Tomográficas de Ciência dos Solos Utilizando Redes Neurais e Combinação de Classificadores**

Fabricio Aparecido Breve

Prof. Dr. Nelson Delfino d'Ávila Mascarenhas

# Apresentação

- Objetivos
- Tomografia Computadorizada / Obtenção das Imagens
- Classificação
  - Redes Neurais
    - Perceptron de Múltiplas Camadas
    - Redes de Função de Base Radial
  - Avaliação de Desempenho dos Classificadores
    - Hold-Out
    - Coeficiente Kappa
  - Combinadores de Classificadores
    - Decision Templates
    - Dempster-Shafer
    - Bagging
- Proposta
- Resultados
- Conclusões
- Produção Bibliográfica

# Objetivos

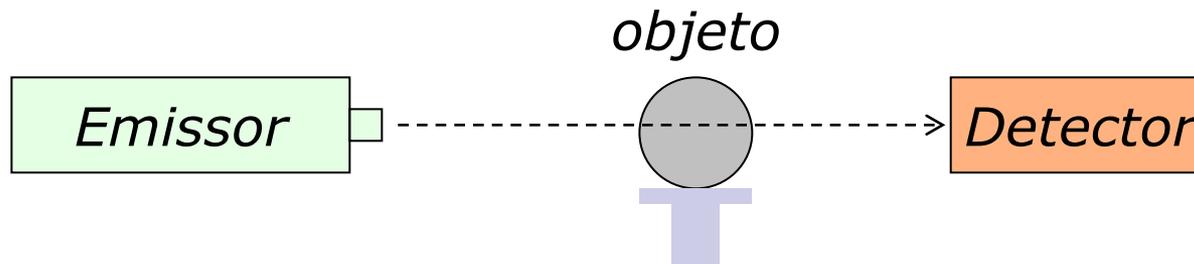
- Identificar materiais em imagens tomográficas multiespectrais utilizando classificadores baseados em redes neurais
- Melhorar desempenho desses classificadores utilizando combinação de classificadores
- Verificar e comparar desempenho dos classificadores e combinadores

# Tomografia Computadorizada

- Método não destrutivo de reconstruir uma imagem a partir de suas projeções (informações derivadas das energias transmitidas, quando o objeto é iluminado a partir de um determinado ângulo)
- Solução matemática apresentada por Radon em 1917
- Primeiro scanner tomográfico computadorizado apresentado por Hounsfield em 1972

# Tomografia Computadorizada

- Imagens tomográficas são obtidas através de um sensor que responde de acordo com a quantidade de fótons que incidem sobre ele
- É possível utilizar sensores com respostas espectrais diferentes, obtendo-se imagens diferentes, mas em um mesmo instante
- **Imagens Multiespectrais:** conjunto total de imagens geradas em um mesmo momento por sensores com diferentes respostas espectrais

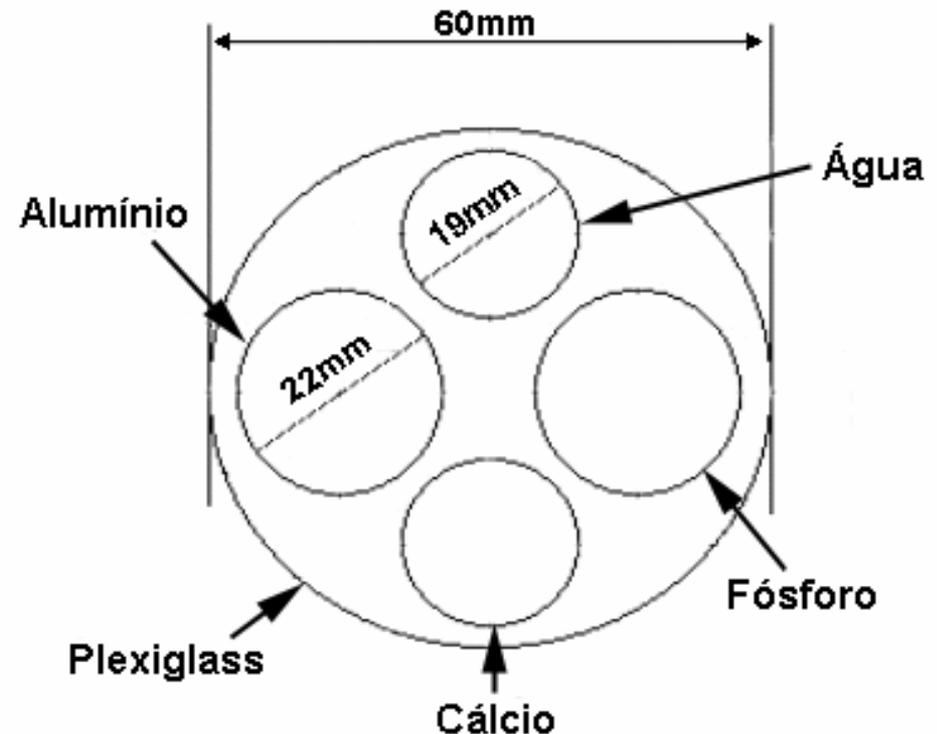


# Tomografia Computadorizada

- Dados de projeção resultam da interação entre a radiação usada e da composição do objeto a ser reconstruído
- **Absorção Fotoelétrica:** um fóton de raio-x concede toda a sua energia para um elétron fortemente ligado
- **Efeito Compton:** um fóton de raio-x interage com um elétron livre ou fracamente ligado, cedendo a ele parte de sua energia e desviando-se de sua trajetória original

# Obtenção das Imagens

- Phantom construído com materiais encontrados no solo
- Suporte de Plexiglass
- 4 Cilindros contendo: Alumínio, Água, Fósforo e Cálcio



# Obtenção das Imagens

- Resolução: 65x65 pixels
- 256 níveis de cinza
- Imagens negativas para melhor visualização
- 3 segundos de exposição (ruído alto)



**40 keV**  
Raio-X



**60 keV**  
Amerício

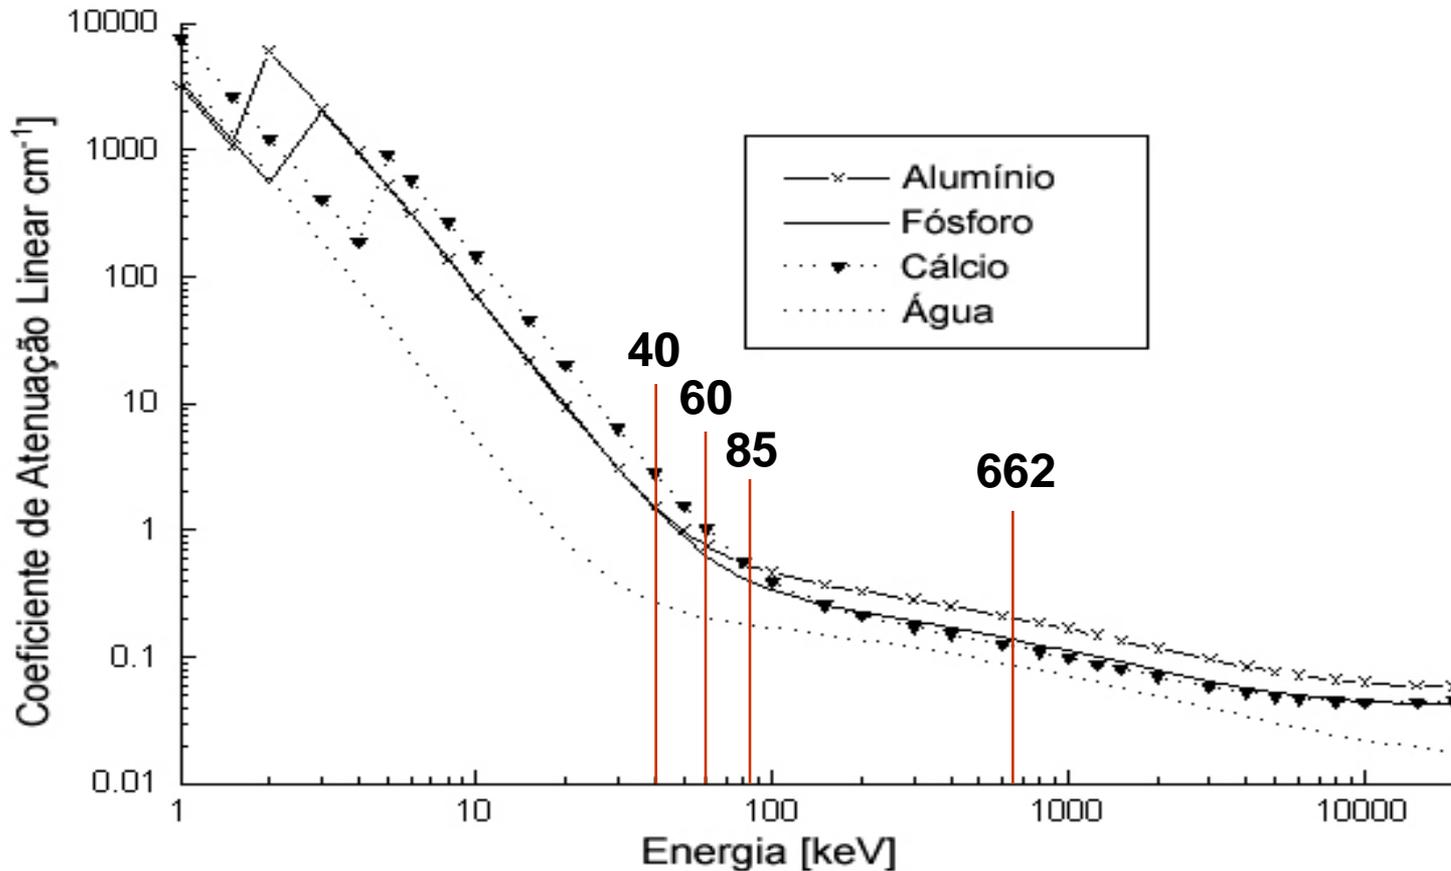


**85 keV**  
Raio-X



**662 keV**  
Césio

# Obtenção das Imagens



- As energias empregadas foram escolhidas pela disponibilidade e pela melhor discriminação entre os materiais

# Reconhecimento de Padrões

- **Objetivo:** classificar objetos de interesse em “categorias” ou “classes”
- **Atributos:** características que podem ser utilizadas para diferenciar os objetos
- **Treinamento Supervisionado:** consiste em utilizar um determinado conjunto de padrões já devidamente rotulados para treinar o classificador

# Reconhecimento de Padrões

- Classificadores utilizados em trabalhos anteriores: (Homem, 1998; Ponti, 2004)
  - Máxima Verossimilhança
  - K-Médias
  - ICM (Interacted Conditional Modes)
  - Bayesiano Linear
  - Logístico
  - Parzen
  - K-Vizinhos Mais Próximos



# Classificadores e Redes Neurais

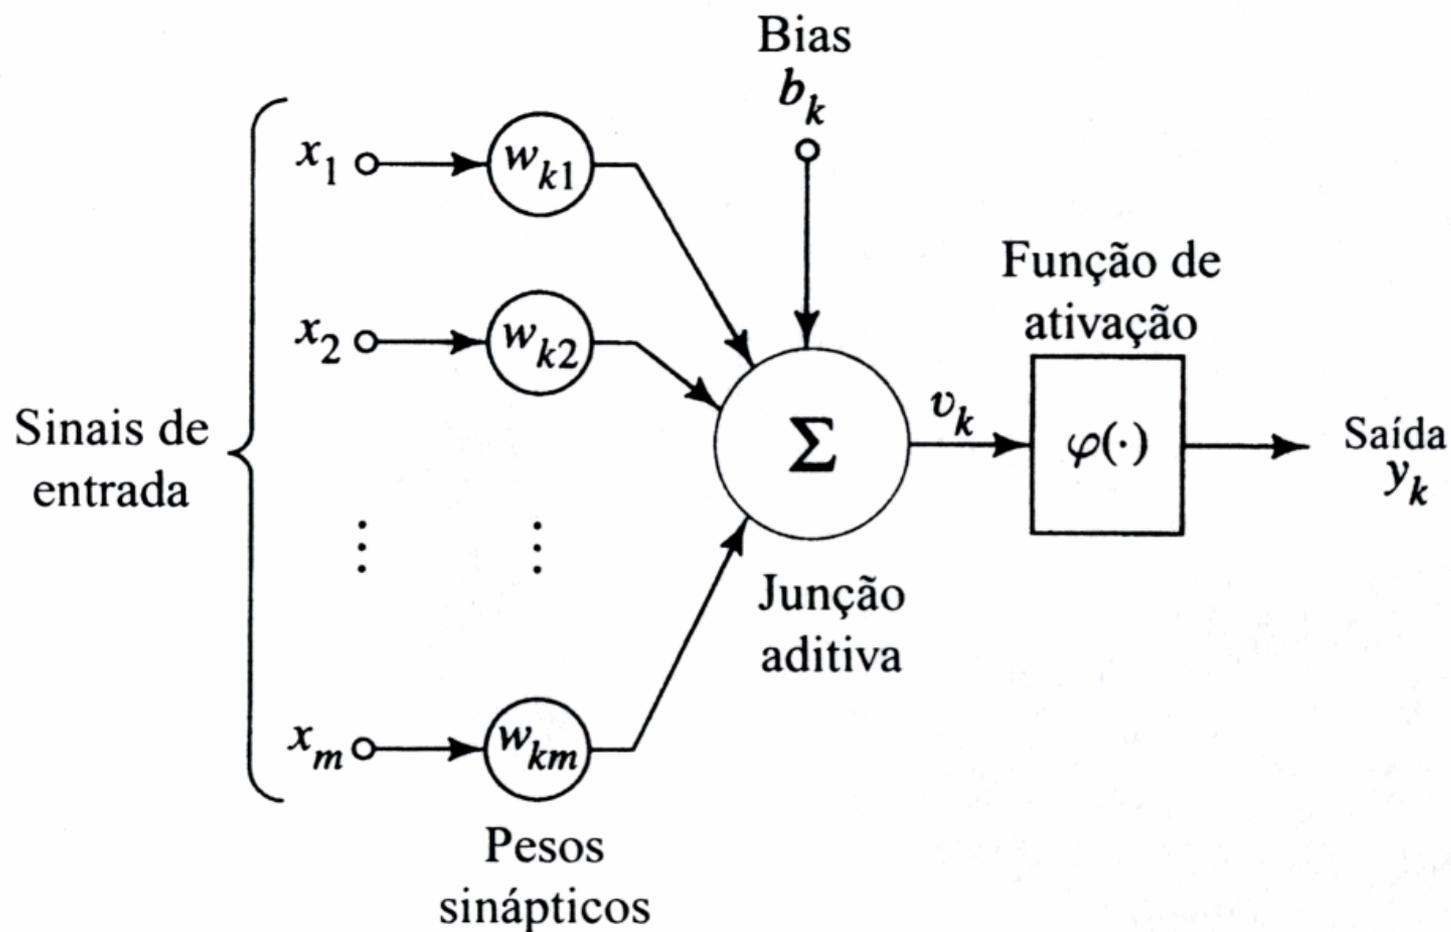
- Estatística:

- Reconhece a natureza probabilística da informação que procuramos para processar e da forma pela qual devemos expressar os resultados.

- Redes Neurais

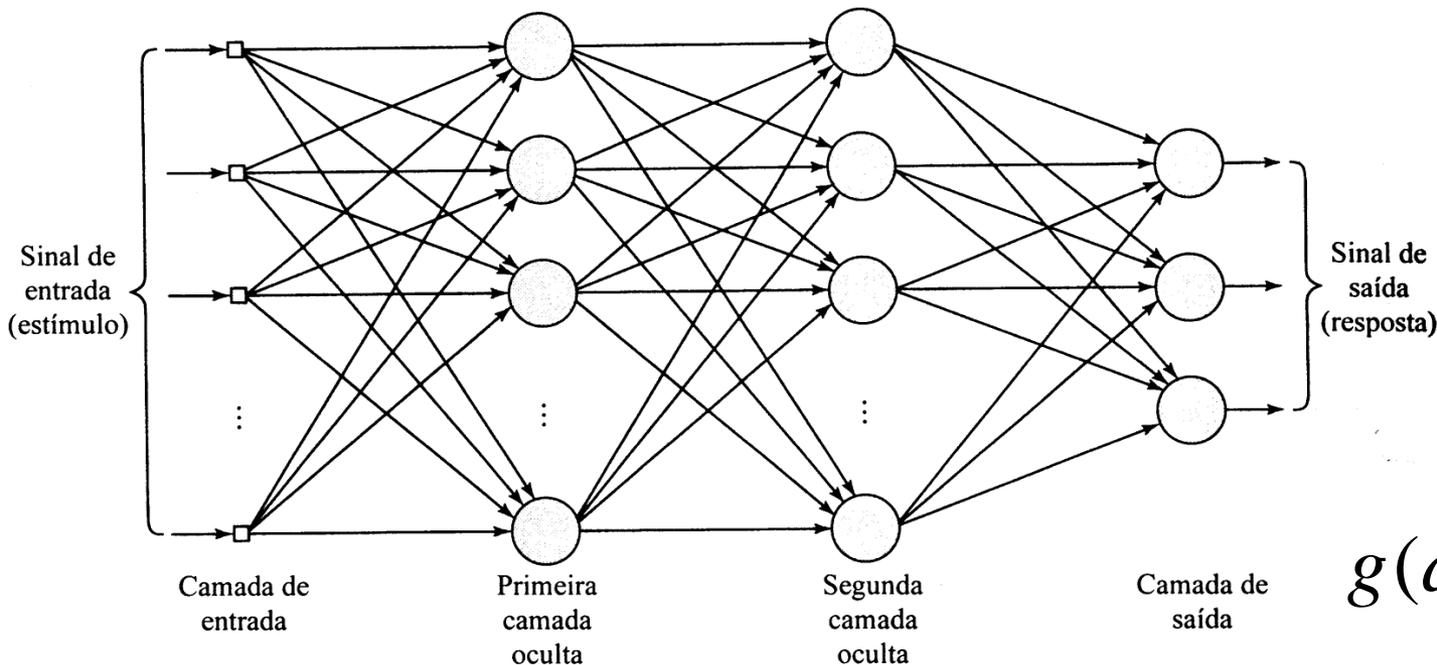
- Motivado pelos estudos da maneira como o cérebro humano processa informações
- O cérebro é um “computador” altamente complexo, não-linear e paralelo

# Redes Neurais - Modelo de um Neurônio



# Perceptron de Múltiplas Camadas

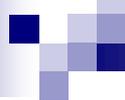
- Uma camada de entrada, uma ou mais camadas intermediária e uma camada de saída
- Treinamento: Algoritmo de Retropropagação
- Camadas intermediárias e ocultas usam funções Sigmoidais



$$g(a) \equiv \frac{1}{1 + \exp(-a)}$$

# Algoritmo de Retropropagação

- consiste basicamente em dois passos:
  - *Passo para frente* em que o sinal aplicado à entrada vai se propagando pelos nós computacionais da rede até chegar aos nós de saída
  - *Passo para trás*, onde todos os pesos sinápticos são ajustados de acordo com uma regra de correção de erro

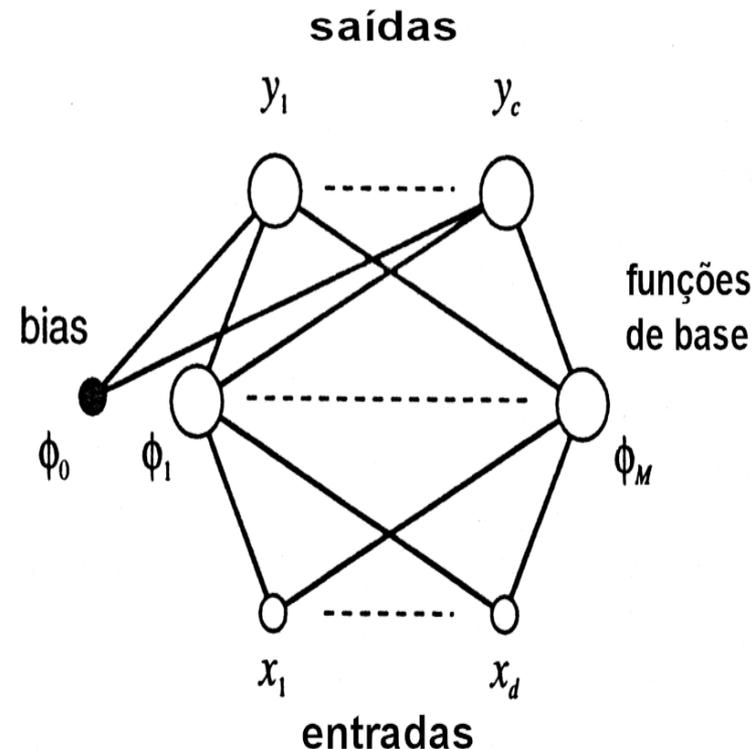


# Redes de Função de Base Radial

- Vê a rede neural como um *problema de ajuste de curva* em um espaço de alta dimensionalidade
- Aprender equivale a encontrar uma superfície num espaço multidimensional que forneça o melhor ajuste para os dados de treinamento do ponto de vista estatístico

# Redes de Função de Base Radial

- Possui 3 camadas:
  - **Entrada:** nós sensoriais que recebem os dados do ambiente.
  - **Intermediária (oculta):** faz uma transformação não-linear do espaço de entrada para um espaço oculto, normalmente de alta dimensionalidade
  - **Saída:** linear, e fornece a resposta da rede ao sinal de entrada



# Avaliação de Desempenho dos Classificadores

## ■ Hold-Out

- Separa-se o conjunto de dados disponíveis (amostras pré-rotuladas) em duas metades. Usa-se uma para treinar o classificador e a outra para testá-lo, obtendo-se a taxa de erro
- É pessimístico porque usa apenas uma porção dos dados para o treinamento

# Avaliação de Desempenho dos Classificadores

## ■ Coeficiente Kappa:

- criado por Cohen em 1960 e pode ser utilizado para medir a concordância entre a saída do classificador e as amostras pré-rotuladas

$$K = \frac{P(A) - P(E)}{1 - P(E)}$$

- Os valores de  $K$  podem variar entre -1 e 1
- $K=1$  total concordância;  $K=0$  nenhuma concordância além da esperada em uma classificação feita ao acaso



# Combinação de Classificadores

- é uma forma de conseguir uma classificação mais precisa, ao custo de ter um aumento na complexidade
- ao combinar classificadores as deficiências de um determinado classificador são compensadas pelas qualidades de outro

# Combinação de Classificadores

## ■ Combinadores utilizados em trabalho anterior: (Ponti, 2004)

- Votação por Maioria
- Máximo
- Mínimo
- Mediana
- Soma
- Produto

## ■ Combinadores utilizados neste trabalho:

- Bagging
- Decision Templates (DT)
- Dempster-Shafer (DS)
- Bagging + DT
- Bagging + DS

# Combinação de Classificadores

- Níveis de informação que um classificador pode fornecer:
  - *Nível abstrato*: o classificador fornece apenas uma única saída que é o rótulo da amostra que foi submetida à classificação
  - *Nível de ranking*: o classificador retorna todos os rótulos possíveis em uma fila com o rótulo mais acima sendo a primeira opção
  - *Nível de medição*: para cada opção de rótulo é atribuído um valor que corresponde à probabilidade daquele ser o rótulo correto.

# Combinação de Classificadores com Valores de Saída Contínuos

- *Perfil de Decisão ( $DP(\mathbf{x})$ )*

$$DP(x) = \begin{bmatrix} d_{1,1}(x) & d_{1,j}(x) & d_{1,c}(x) \\ d_{i,1}(x) & d_{i,j}(x) & d_{i,c}(x) \\ d_{L,1}(x) & d_{L,j}(x) & d_{L,c}(x) \end{bmatrix}$$

# Decision Templates

- É construído um Decision Profile (DP) com a saída de todos os classificadores dada uma amostra
- Um Decision Template (DT) é a média de todos os DPs (um por amostra) de uma determinada classe
- O rótulo de uma amostra de teste é escolhido comparando o seu DP com o DT de cada classe e escolhendo o mais similar
- Aproveita inclusive os erros de classificação

# Dempster-Shafer

- Baseado na teoria da evidência, uma maneira de representar conhecimento cognitivo
- Semelhante ao método Decision Templates, porém, para cada amostra é calculada a proximidade entre o Decision Template e a saída de cada classificador

$$\phi_{j,i}(x) = \frac{(1 + \|DT_j^i - D_i(x)\|^2)^{-1}}{\sum_{k=1}^c (1 + \|DT_i^k - D_i(x)\|^2)^{-1}}$$

# Dempster-Shafer

- Estas proximidades são usadas para calcular um grau de crença para cada classe e cada classificador
- O grau de suporte final para cada classe é calculado a partir destes graus de crença

$$b_j(D_i(x)) = \frac{\phi_{j,i} \prod_{k \neq j} (1 - \phi_{k,i}(x))}{1 - \phi_{j,i}(x) [1 - \prod_{k \neq j} (1 - \phi_{k,i}(x))]}$$

$$\mu_j(x) = K \prod_{i=1}^L b_j(D_i(x))$$

# Bagging

- Criado por Breiman em 1996
- Acrônimo para *Bootstrap AGGregatING*
- Consiste em construir réplicas do tipo *bootstrap* do conjunto de treinamento e treiná-las individualmente
- Saída dos diversos classificadores é então combinada usando votação
- Ideal para classificadores base instáveis (ex.: Perceptron)

# Proposta

- Identificar materiais em imagens multiespectrais de tomografia de solo
- Classificadores propostos:
  - Perceptron de Múltiplas Camadas
  - Redes de Função de Base Radial
- Combinadores de Classificadores Propostos:
  - Bagging (média)
  - Decision Templates
  - Dempster-Shafer
  - Bagging + Decision Templates
  - Bagging + Dempster-Shafer
- Avaliação de Desempenho Proposta:
  - Método Hold-Out (50-50)
  - Coeficiente Kappa



# Proposta

- Ferramentas de Implementação

1. Matlab

- Facilidade para operações com matrizes
- Toolbox para Redes Neurais

2. PRTools

- Toolbox desenvolvido na Universidade de Delft (Holanda)
- Cobre grande parte das técnicas de Reconhecimento de Padrões

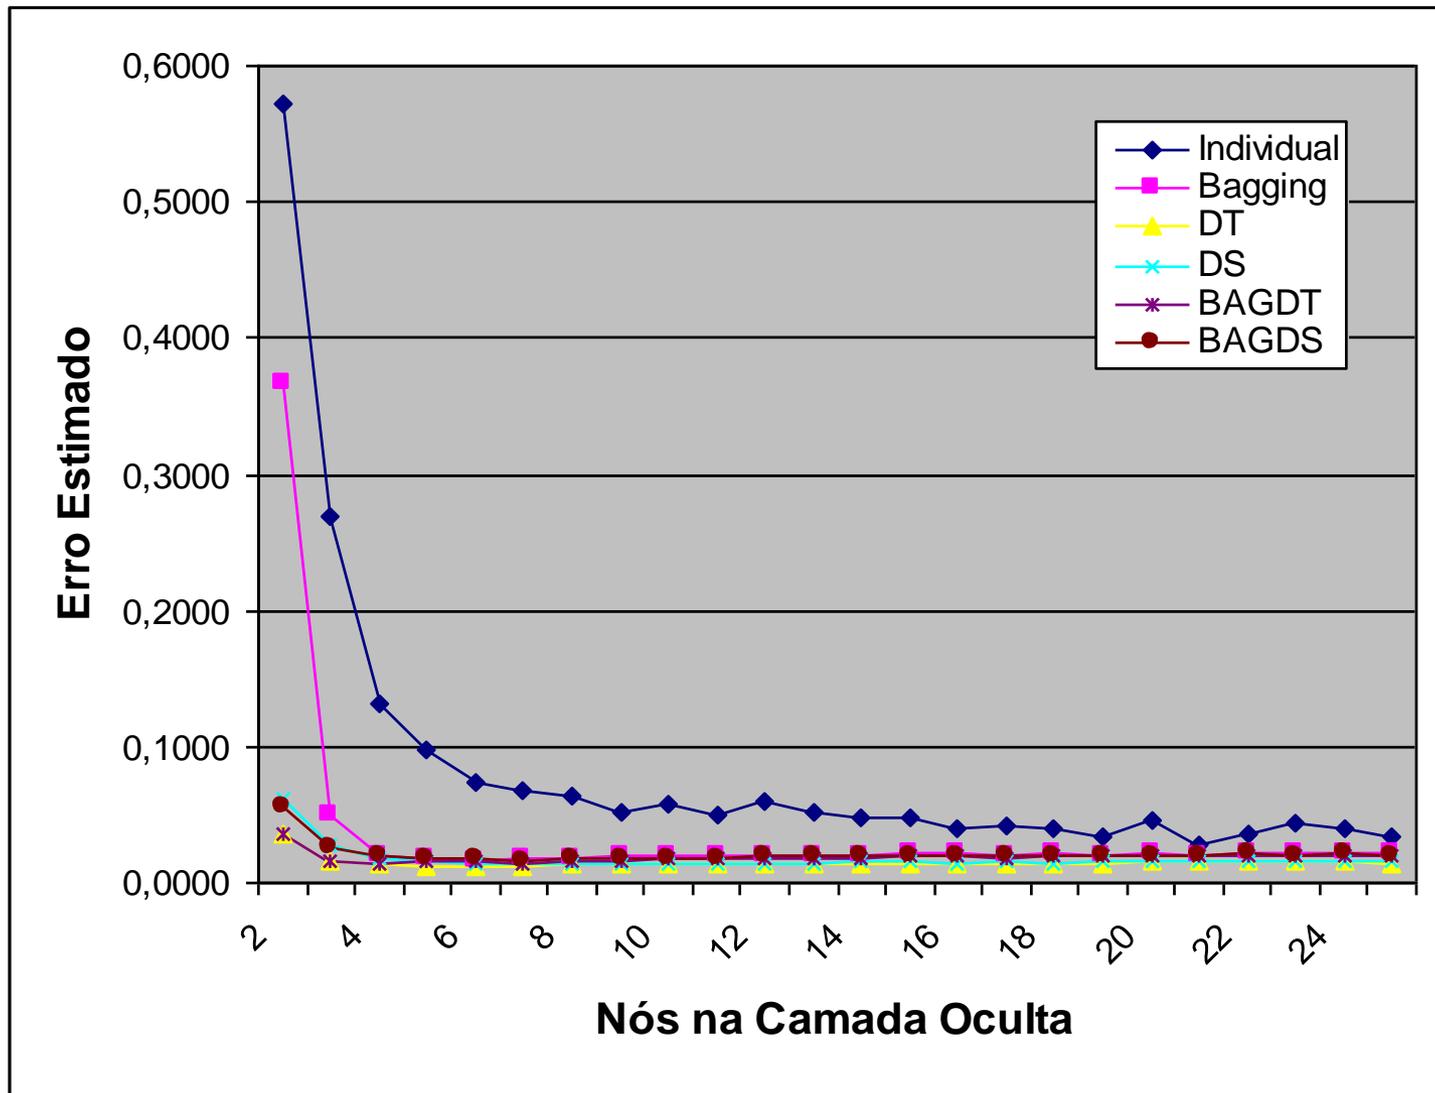
# Experimentos

- 480 amostras (80 de cada uma das 6 classes):
  - Alumínio
  - Água
  - Fósforo
  - Cálcio
  - Plexiglass
  - Fundo
- 240 amostras (40 de cada classe) para treinamento
- 240 amostras para teste

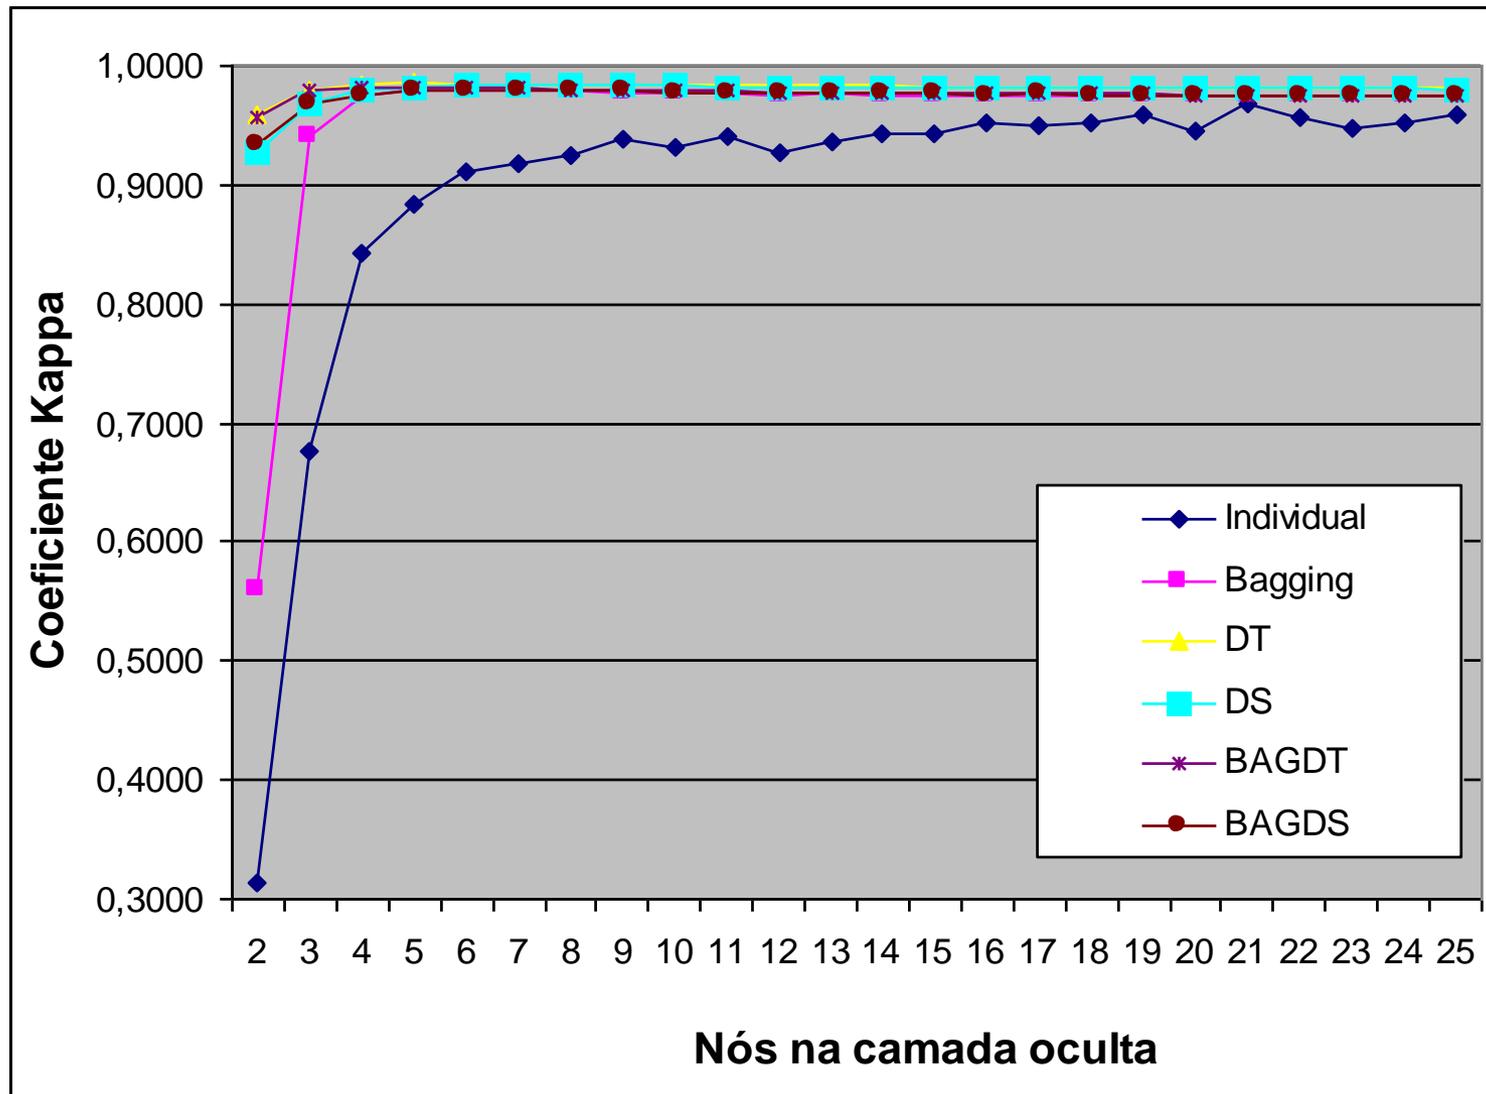
# Experimentos

- Redes com 2 a 25 nós na camada oculta (Perceptron usando apenas uma camada oculta)
- Cada experimento para todos os métodos de classificação foram executados 100 vezes
- Todos os experimentos com combinadores de classificadores utilizaram 10 classificadores-base com diferentes inicializações (e também diferentes amostras nos experimentos com Bagging)

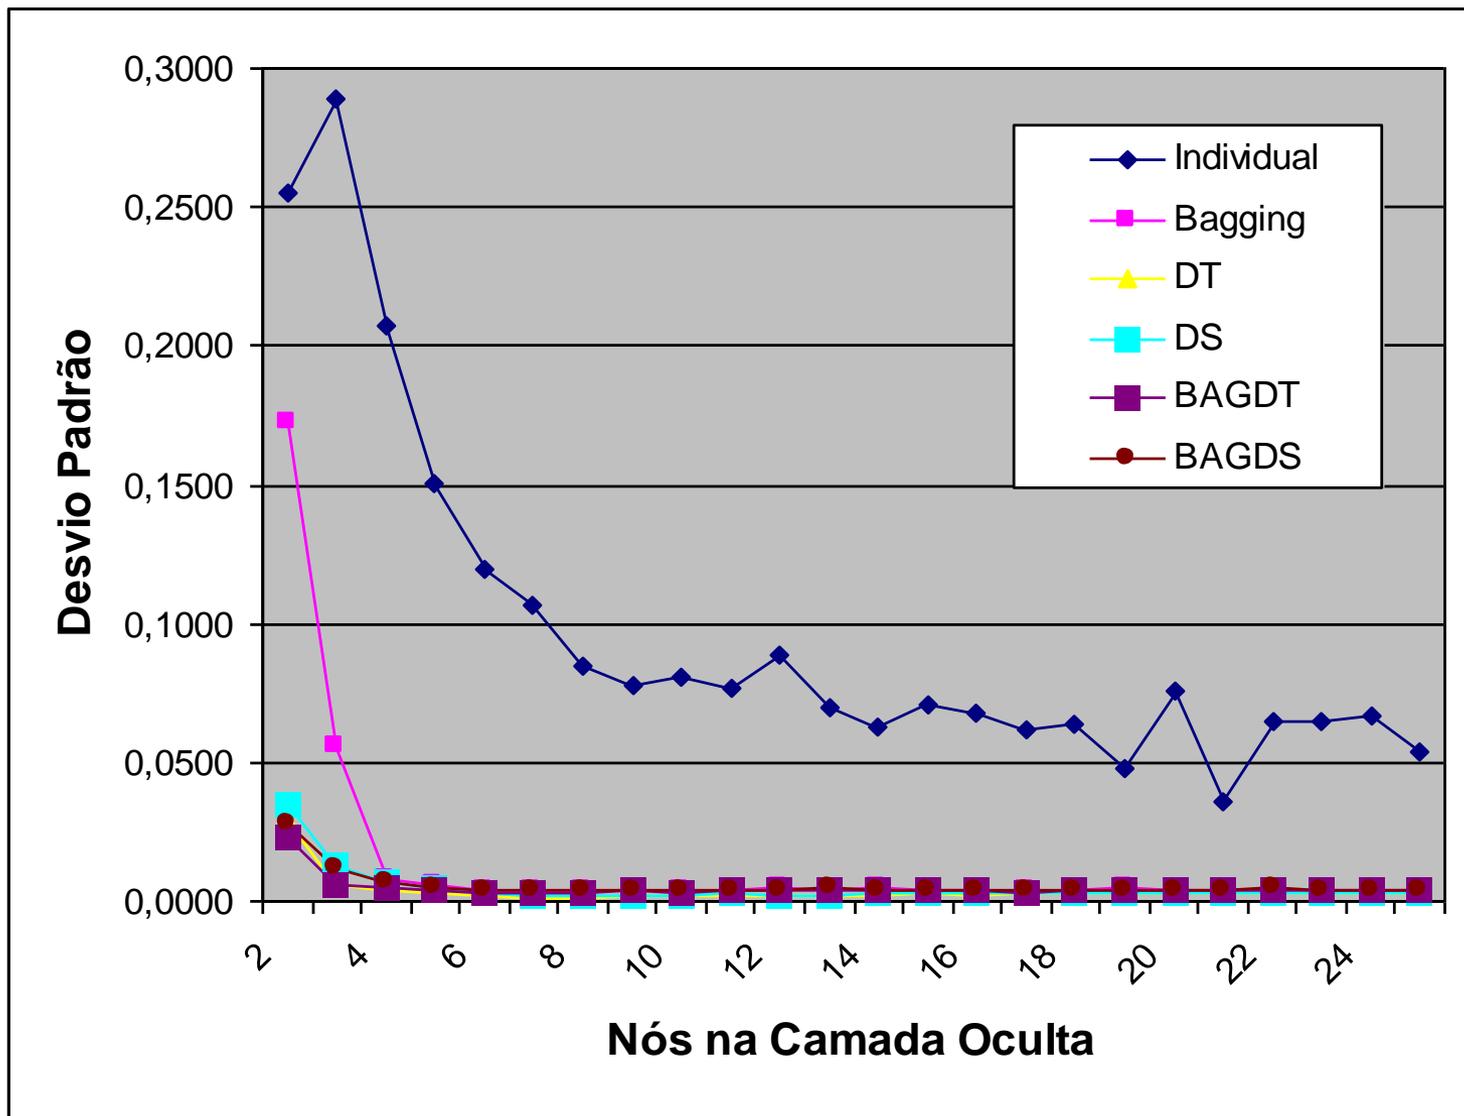
# Resultados - Erro Estimado médio para o Perceptron de Múltiplas Camadas



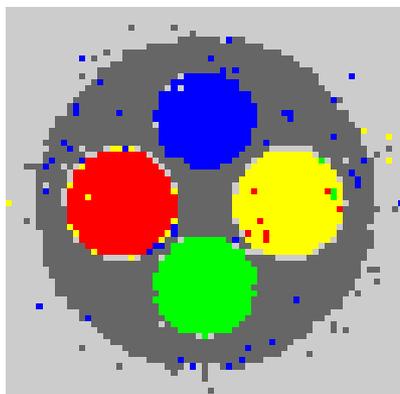
# Resultados – Coeficiente Kappa médio para o Perceptron de Múltiplas Camadas



# Resultados – Desvio Padrão médio para o Perceptron de Múltiplas Camadas

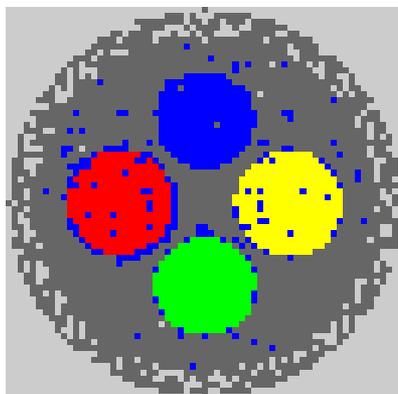


# Imagens Temáticas – Perceptron de Múltiplas Camadas



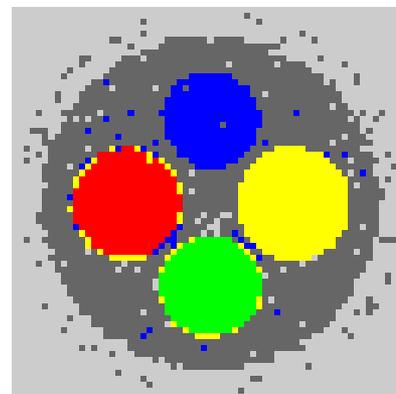
Individual

Erro: 0,0125 / Kappa: 0,9850



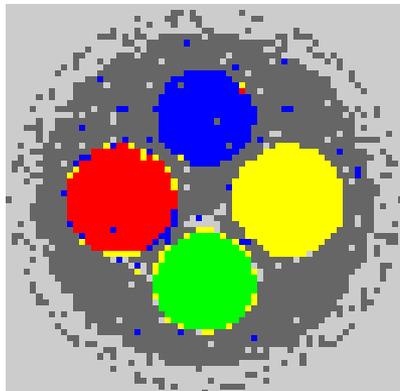
Bagging

Erro: 0,0250 / Kappa: 0,9700



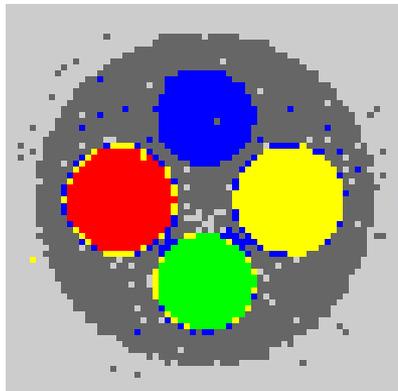
Decision Templates

Erro: 0,0083 / Kappa: 0,9900



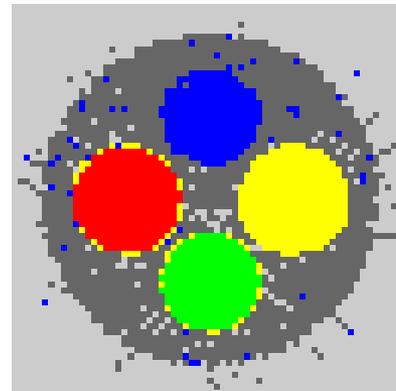
Dempster-Shafer

Erro: 0,0125 / Kappa: 0,9850



Bagging c/ Decision Templates

Erro: 0,0083 / Kappa: 0,9900



Bagging c/ Dempster-Shafer

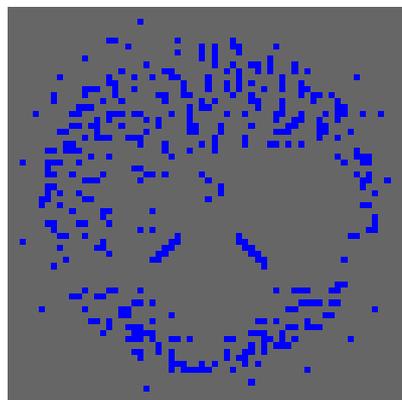
Erro: 0,0083 / Kappa: 0,9900

Imagens Temáticas para Perceptron de Múltiplas Camadas com 2 nós na camada oculta (melhores casos)

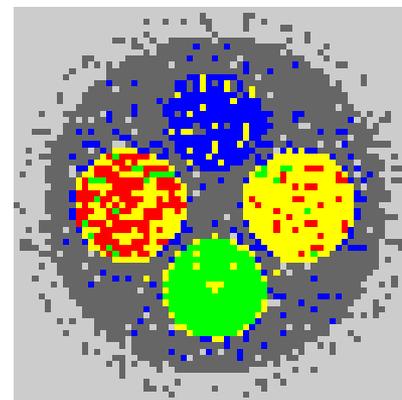
# Imagens Temáticas – Perceptron de Múltiplas Camadas



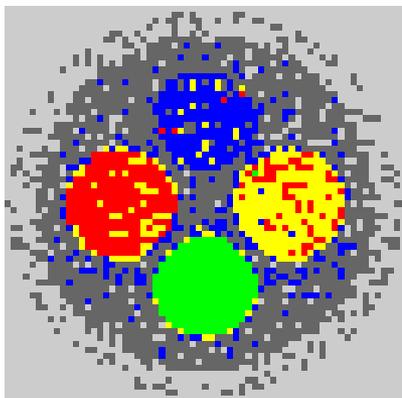
Classificador Individual  
Erro: 0,8792 / Kappa: -0,0550



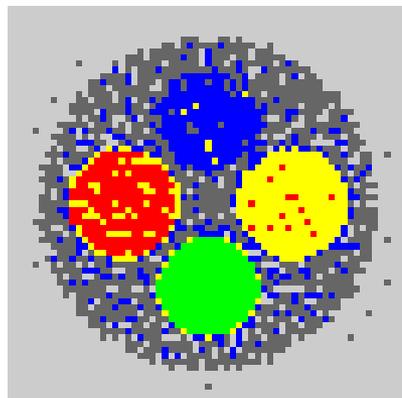
Bagging  
Erro: 0,8500 / Kappa: -0,0200



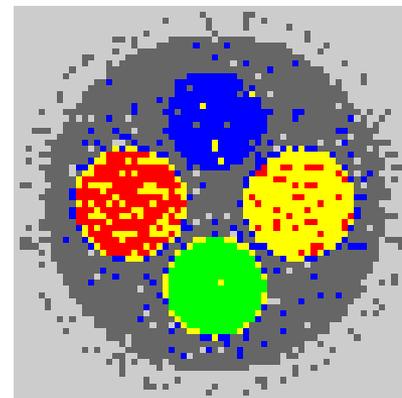
Decision Templates  
Erro: 0,1708 / Kappa: 0,7950



Dempster-Shafer  
Erro: 0,1500 / Kappa: 0,8200



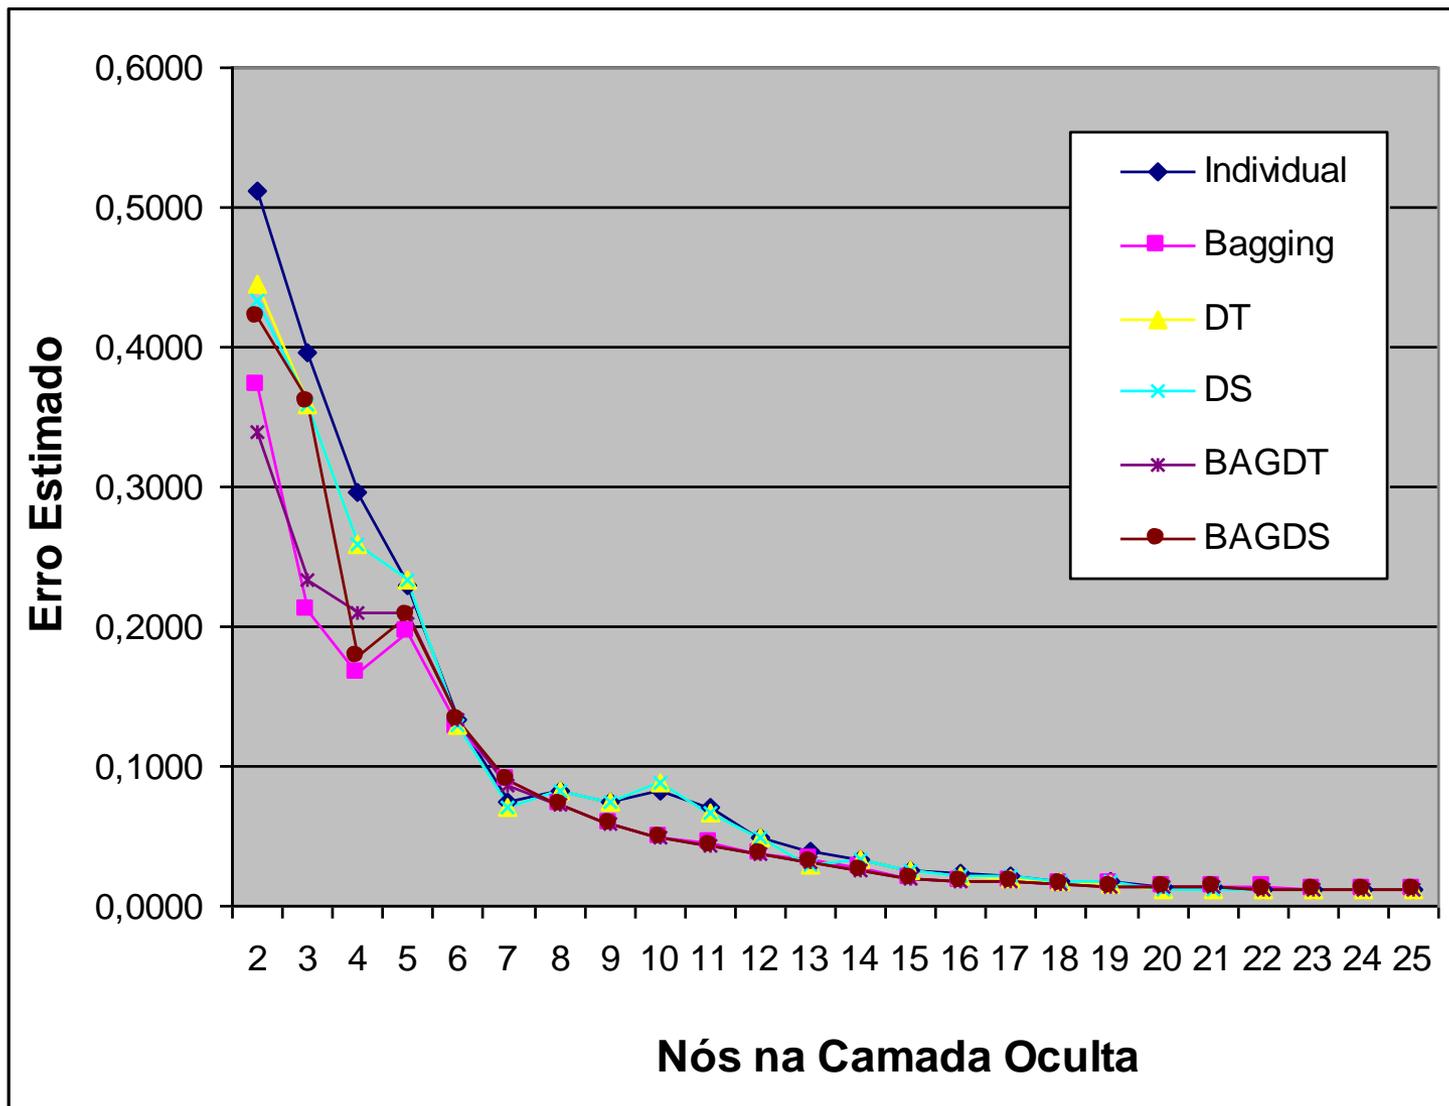
Bagging c/ Decision Templates  
Erro: 0,1208 / Kappa: 0,8550



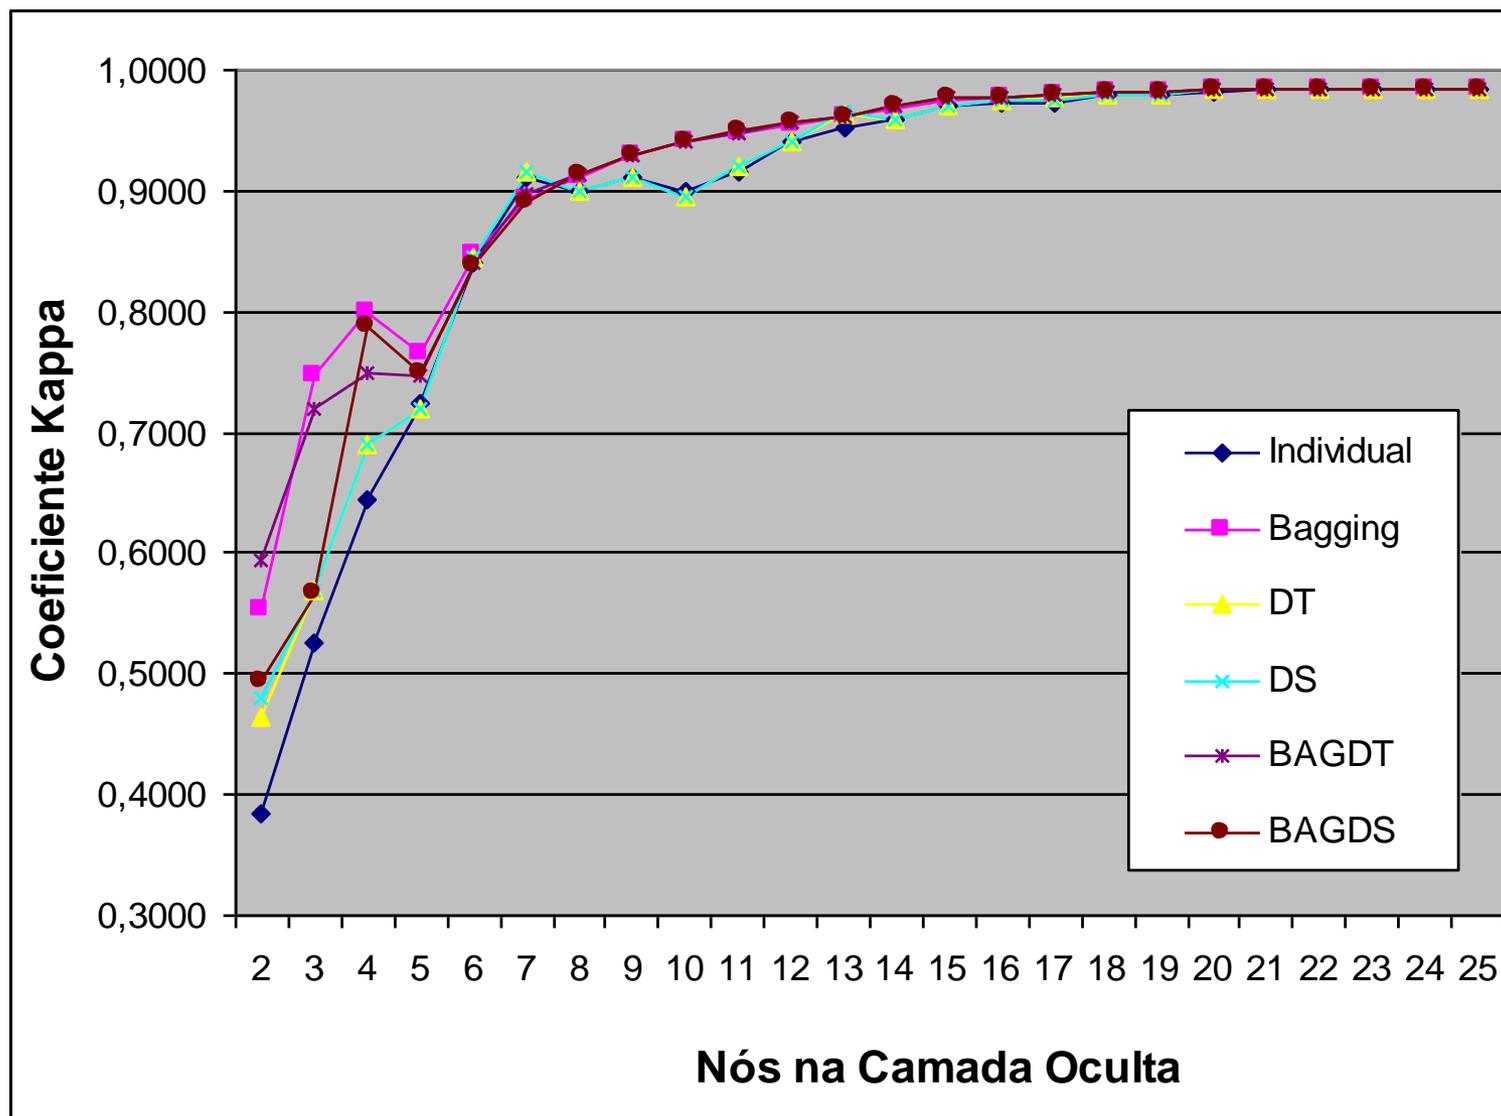
Bagging c/ Dempster-Shafer  
Erro: 0,1333 / Kappa: 0,8400

Imagens Temáticas para Perceptron de Múltiplas Camadas com 2 nós na camada oculta (piores casos)

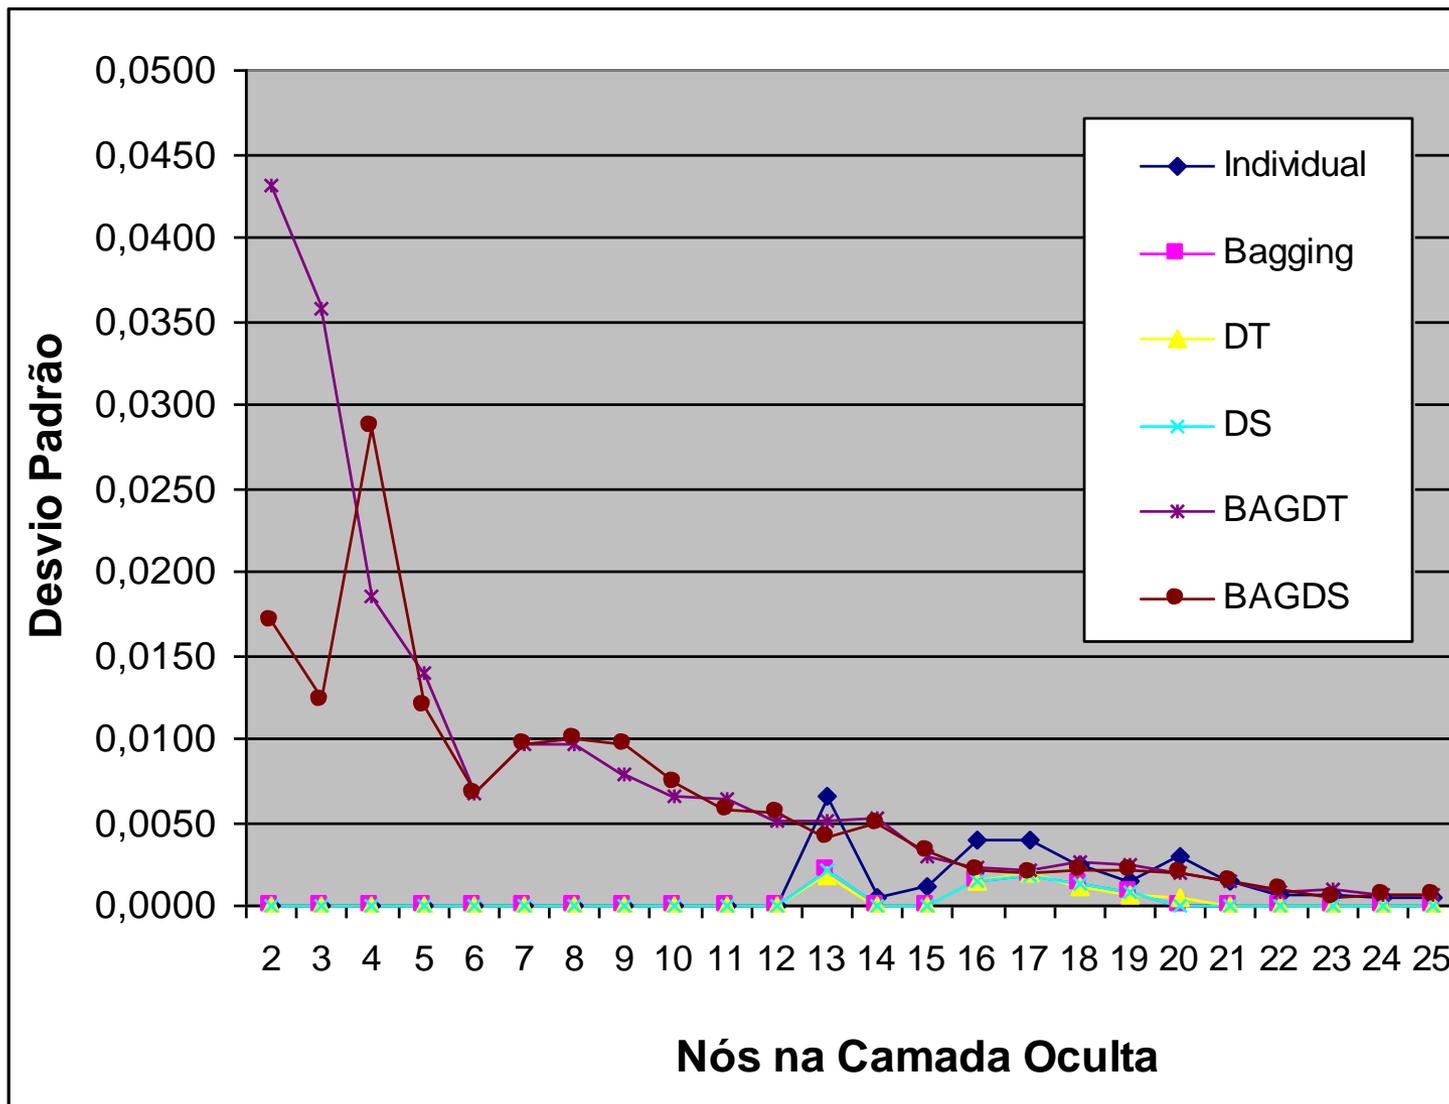
# Resultados - Erro Estimado médio para Redes de Função de Base Radial



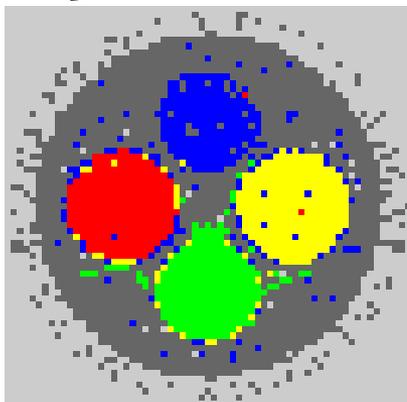
# Resultados – Coeficiente Kappa médio para Redes de Função de Base Radial



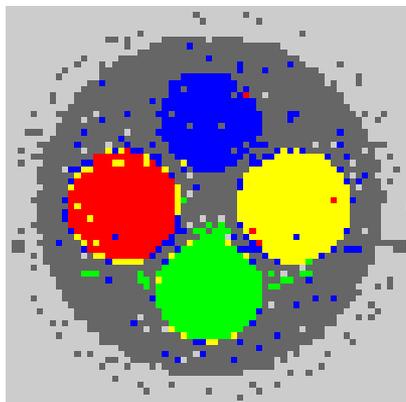
# Resultados – Desvio Padrão médio para Redes de Função de Base Radial



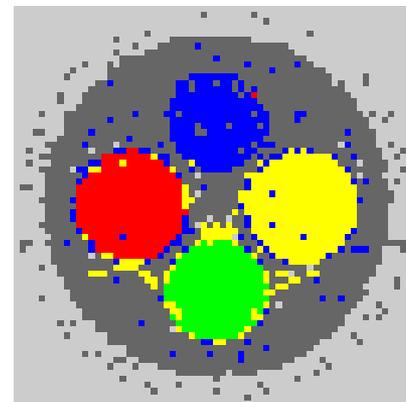
# Imagens Temáticas – Redes de Função de Base Radial



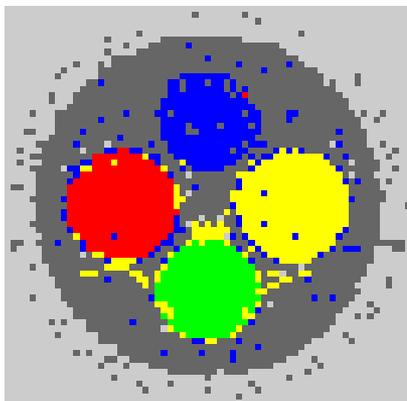
Individual  
Erro: 0,0333 / Kappa: 0,9600



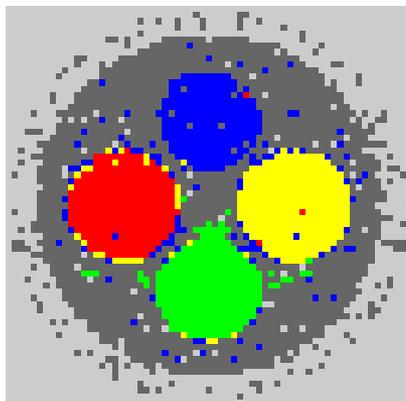
Bagging  
Erro: 0,0208 / Kappa: 0,9750



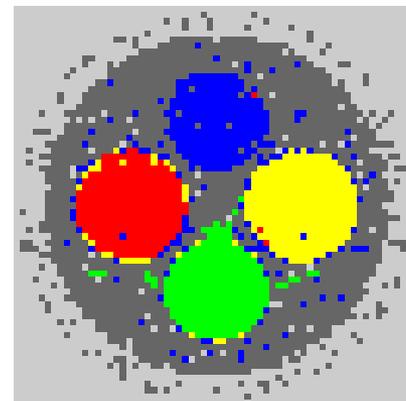
Decision Templates  
Erro: 0,0292 / Kappa: 0,9650



Dempster-Shafer  
Erro: 0,0292 / Kappa: 0,9650



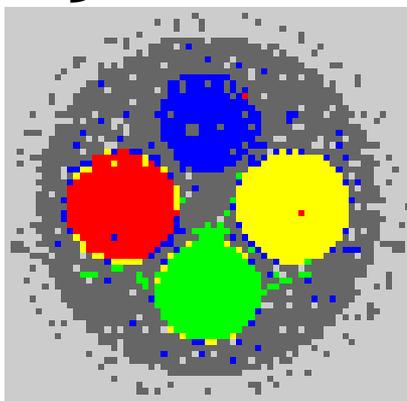
Bagging c/ Decision Templates  
Erro: 0,0208 / Kappa: 0,9750



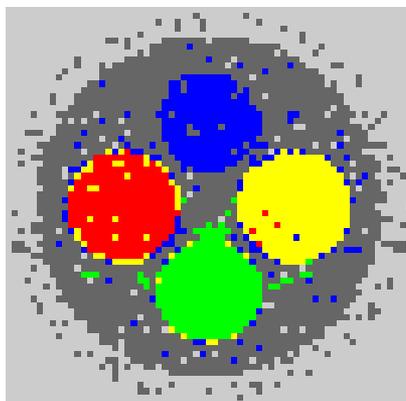
Bagging c/ Dempster-Shafer  
Erro: 0,0208 / Kappa: 0,9750

Imagens Temáticas para Redes de Função de Base Radial com 13 nós na camada oculta (melhores casos)

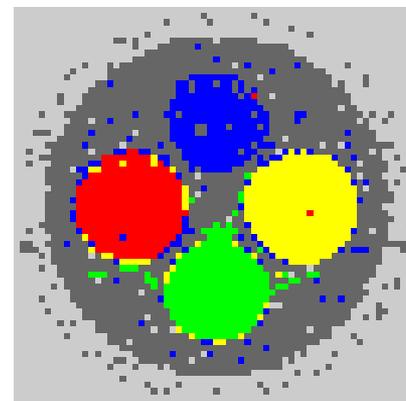
# Imagens Temáticas – Redes de Função de Base Radial



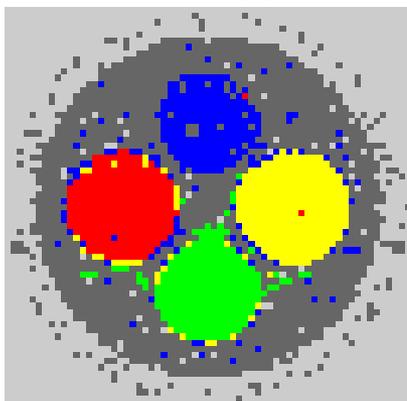
Individual  
Erro: 0,0500 / Kappa: 0,9400



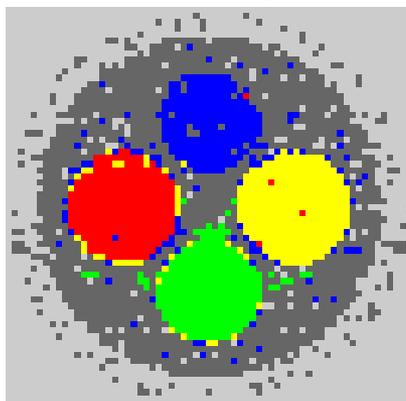
Bagging  
Erro: 0,0458 / Kappa: 0,9750



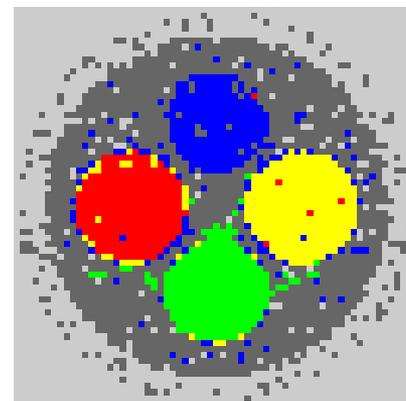
Decision Templates  
Erro: 0,0375 / Kappa: 0,9550



Dempster-Shafer  
Erro: 0,0375 / Kappa: 0,9550



Bagging c/ Decision Templates  
Erro: 0,0458 / Kappa: 0,9450



Bagging c/ Dempster-Shafer  
Erro: 0,0458 / Kappa: 0,9450

Imagens Temáticas para Redes de Função de Base Radial com 13 nós na camada oculta (piores casos)

# Conclusões

- O uso de combinadores produz *resultados mais estáveis* e melhora significativamente o *desempenho dos classificadores*
- Perceptron de Múltiplas Camadas
  - *Decision Templates* e *Dempster-Shafer* apresentam melhor desempenho que técnicas com *Bagging*
- Redes de Função de Base Radial
  - Técnicas com *Bagging* apresentam melhor desempenho que *Decision Templates* e *Dempster-Shafer*

# Conclusões

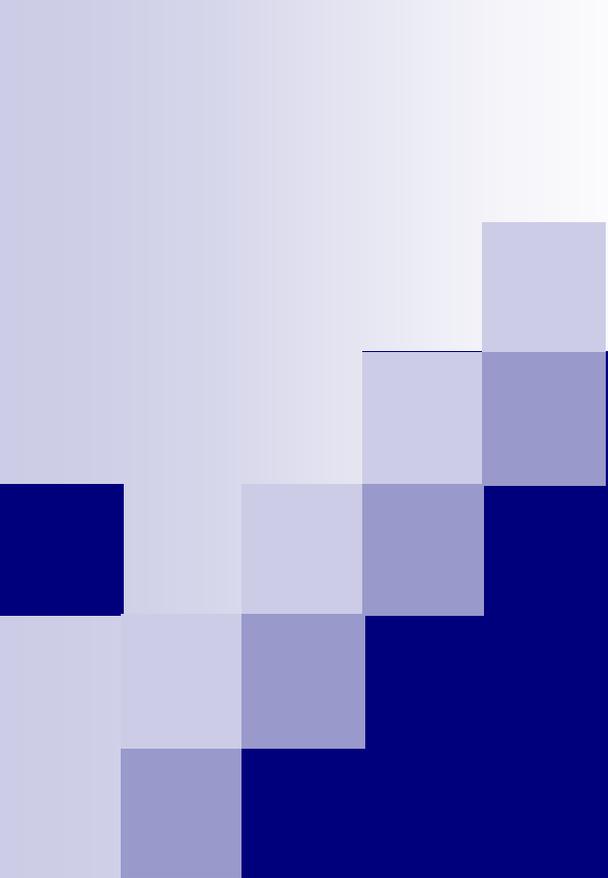
- **Decision Templates:** o mais indicado para o Perceptron de Múltiplas Camadas
  - diferenças nas redes causadas pela inicialização aleatória dos parâmetros livres já são suficientes para produzir classificadores bastante diferentes e bons para combinação
  - combinador que deixou o Perceptron mais estável

# Conclusões

- **Bagging:** o mais indicado para Redes de Função de Base Radial
  - leva vantagem por utilizar conjuntos de amostras do tipo bootstrap, produzindo classificadores diferentes para a combinação
  - Bagging c/ Decision Templates também apresenta um bom desempenho, porém traz uma leve instabilidade

# Produção Bibliográfica

- Publicação em Congresso (full paper):
  - Breve, F. A.; Ponti Jr, M. P.; Mascarenhas, N. D. A., *Combining Methods to Stabilize and Increase Performance of Neural Network-Based Classifiers*. In: Proceedings of SIBGRAPI 2005, XVIII Brazilian Symposium on Computer Graphics and Image Processing. Natal, Brazil: IEEE CS Press, 2005.
- Publicação em Congresso (resumo):
  - Breve, F. A.; Mascarenhas, N. D. A. *Classificação de Imagens Tomográficas de Ciência dos Solos Utilizando Redes Neurais e Combinação de Classificadores*. Anais do III Congresso de Pós-Graduação - 6ª Jornada Científica da UFSCar. São Carlos, 2005.
- Artigo Submetido para Periódico Internacional:
  - Breve, F. A.; Ponti Jr, M. P.; Mascarenhas, N. D. A., *Neural-Network Combination for Noisy Data Classification*. (submetido para Pattern Analysis and Applications)



# **Classificação de Imagens Tomográficas de Ciência dos Solos Utilizando Redes Neurais e Combinação de Classificadores**

Fabricio Aparecido Breve

Prof. Dr. Nelson Delfino d'Ávila Mascarenhas