

Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Biológicas
Programa de Pós-Graduação em Ciência da Computação

PCC146
RECONHECIMENTO DE PADRÕES
Trabalho Pacial

Eduardo Luz
Rensso Mora Colque
Professor - David Menotti

Ouro Preto
15 de novembro de 2010

Sumário

1	Introdução	1
2	Método proposto por Guler e Ubeyli, 2005	1
2.1	Primeira abordagem	2
2.2	Segunda abordagem	3
3	Método proposto por Yu e Chen, 2007	5
3.1	Classificação com rede neuronal probabilística	5
3.2	Primeiro grupo	6
3.3	Segundo grupo	6
3.4	Classificação com MLP	7
4	Método proposto por Song et al, 2005	7
4.1	Toolbox de bioinformática do Matlab	8
4.2	Libsvm	8
5	Conclusão	9

Lista de Figuras

1	Tabela extraída do trabalho de Guler e Ubeyli, 2005[1]	1
2	Matrix de confusão da rede MLP <i>standalone</i>	2
3	Tempo de treinamento da rede MLP <i>standalone</i>	2
4	Topologia de uma rede neuronal combinada, extraída do artigo de Guler e Ubeyli, 2005	3
5	Matriz de confusão da rede MLP combinada, para abordagem 1	3
6	Matrix de confusão da rede MLP para detecção de batimentos do tipo A(classe 1) ou demais classe(classe 2)	4
7	Matrix de confusão da rede MLP combinada, para abordagem 2	4
8	Arquitetura de uma rede neuronal probabilística	6
9	Matriz de confusão para o primeiro grupo de características	7
10	Matriz de confusão para o segundo grupo de características	8

1 Introdução

O presente trabalho visa efetuar uma comparação entre três métodos distintos para classificação de arritmias no sinal de ECG.

Os autores dos trabalhos em análise utilizaram o banco de dados de arritmia do MIT-BIH. Para o presente trabalho, o banco de dados de arritmia do MIT-BIH também foi utilizado, mas os registros foram escolhidos aleatoriamente (116, 118, 119, 124, 200, 207, 208, 210, 212, 221, 222, 232 e 233). Os tipos de batimentos(classes) escolhidos foram : batimento normal (N), batimento atrial prematuro(A), contração ventricular prematura (V) e *Right bundle branch block beat* (R), visando facilitar a comparação entre os métodos. Estes tipos de batimentos foram os encontrados em maior abundância nos registros escolhidos.

2 Método proposto por Guler e Ubeyli, 2005

Guler e Ubeyli[1] propuseram um método para detecção de arritmias no sinal de ECG por meio de redes neuronais combinadas. A transformada wavelet foi utilizada como principal ferramenta para extração de características e o número de níveis de decomposição usado foi 4. Assim, o sinal foi decomposto em 4 sinais de detalhe (D1 - D4) e um sinal de aproximação (A4) totalizando 256 coeficientes. Estes coeficientes foram reduzidos a 19 características, de acordo com as regras abaixo:

- Média absoluta dos coeficientes em cada sub-banda (D1 - A4).
- Potência média dos coeficientes de cada sub-banda (D1 - A4).
- Desvio padrão dos coeficientes de cada sub-banda (D1 - A4).
- Razão da média absoluta das subbandas adjacentes.

Os dois primeiros grupos de características representam a distribuição do sinal e as outras características representam mudanças na distribuição da frequência.

Os autores fizeram um estudo do impacto do tipo de transformada wavelet utilizada e mostraram que, para o método em foco, a transformada do tipo Daubechies de ordem 2 promoveu os melhores resultados na classificação dos tipos de arritmia utilizando-se redes neuronais combinadas (ver Figura 1).

Wavelet type	Total classification accuracy (%)
sym6	90.28
sym10	90.83
coif4	91.11
coif2	91.67
db1	93.06
db6	94.17
db2	96.94

Figura 1: Tabela extraída do trabalho de Guler e Ubeyli, 2005[1]

2.1 Primeira abordagem

Após a extração de 180 vetores de características para cada classe, uma rede neuronal com 19 entradas, 25 neurônios na camada escondida e 4 neurônios na saída foi construída. Foi utilizado 50% dos dados para treino, 20% para validação e 30% para teste. O melhor resultado conseguido foi um erro de total de 7.8%, sendo que pela matrix de confusão é possível ver que existe uma confusão entre as classes 2 e 4 (ver Figura 2). O treinamento durou 83 épocas (ver Figura 3).

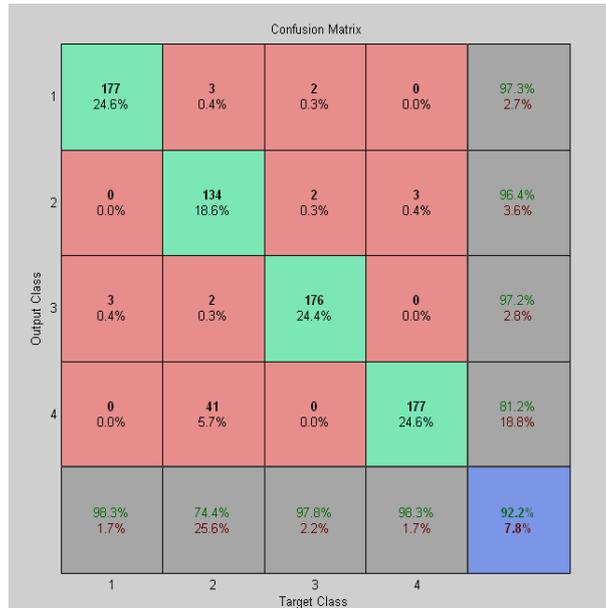


Figura 2: Matrix de confusão da rede MLP *standalone*

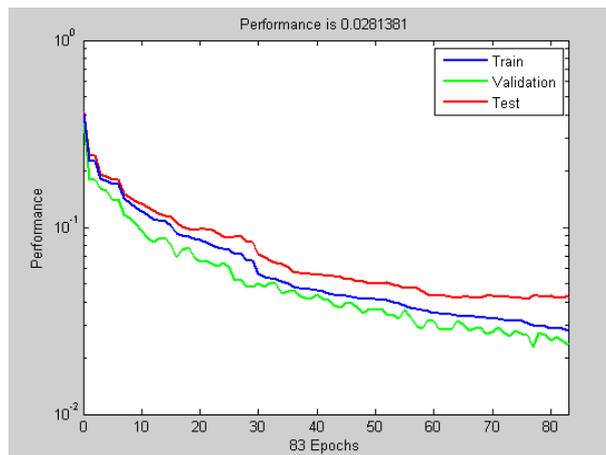


Figura 3: Tempo de treinamento da rede MLP *standalone*

Quatro redes neuronais foram utilizadas para criar um novo conjunto de vetores de entrada para a o segundo nível da rede neuronal. A rede para o segundo nível possui 16 entradas, 30 neurônios na camada escondida e 4 saídas, como a Figura 4.

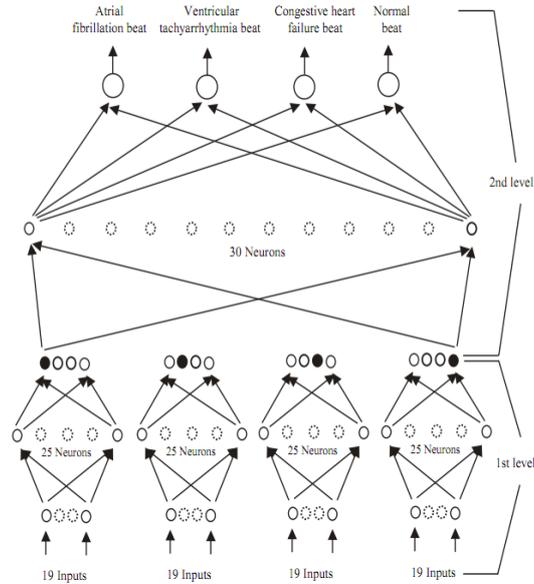


Figura 4: Topologia de uma rede neuronal combinada, extraída do artigo de Guler e Ubeyli, 2005

Em média, a precisão obtida pela rede combinada é maior que as obtidas pelas redes *standalone*. Com alguns testes foi possível obter um resultado de 97.2% de precisão, como na Figura 5.

Output Class	1	2	3	4	
1	180 25.0%	0 0.0%	1 0.1%	0 0.0%	99.4% 0.6%
2	0 0.0%	163 22.6%	0 0.0%	2 0.3%	98.8% 1.2%
3	0 0.0%	1 0.1%	179 24.9%	0 0.0%	99.4% 0.6%
4	0 0.0%	16 2.2%	0 0.0%	178 24.7%	91.8% 8.2%
	100% 0.0%	90.6% 9.4%	99.4% 0.6%	98.9% 1.1%	97.2% 2.8%
	1	2	3	4	
	Target Class				

Figura 5: Matriz de confusão da rede MLP combinada, para abordagem 1

2.2 Segunda abordagem

Para a segunda abordagem, as redes *standalone* foram modificadas de modo que cada uma foi projetada para detectar apenas um tipo de batimento dentre os demais,

como exemplificado pela Figura 6

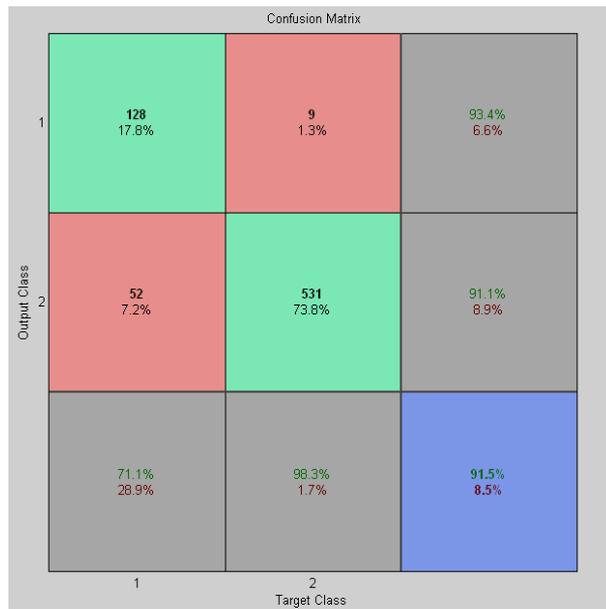


Figura 6: Matrix de confusão da rede MLP para detecção de batimentos do tipo A(class 1) ou demais classe(class 2)

Neste caso, foi utilizado 8 entradas para a rede do segundo nível e 15 neurônios na camada escondida . Os resultados foram inferiores ao do primeiro nível (ver Figura 7)

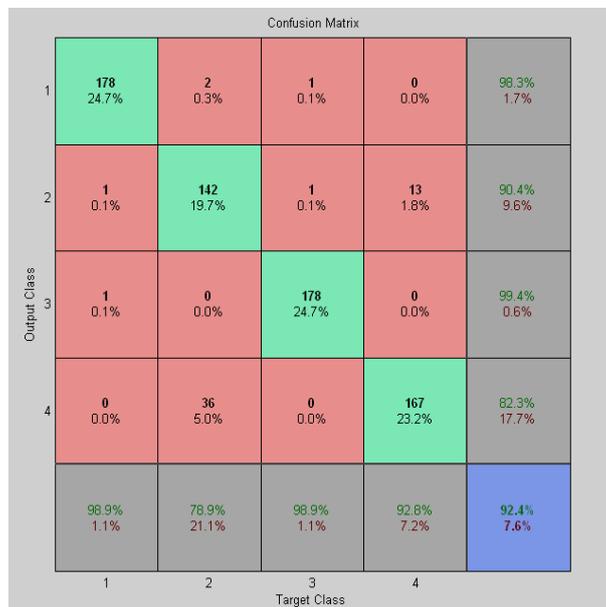


Figura 7: Matrix de confusão da rede MLP combinada, para abordagem 2

3 Método proposto por Yu e Chen, 2007

O artigo analisado nesta seção [3] propõem uma classificação de arritmias no sinal de ECG com redes neuronais probabilísticas.

A extração das características foi baseada em transformada wavelet decomposta em dois níveis. Os sinais de aproximação do nível 2(A2) e detalhe dos níveis 1 e 2(D1 e D2) foram utilizados para a construção das características. No artigo em análise, dois grupos de características foram utilizados. O primeiro grupo é formado por 10 características e foi construído com base nas regras abaixo:

- Variância de 128 amostras em torno do pico R.
- Variância dos coeficientes em cada sub-banda da WT utilizada (A2, D1 e D2).
- Variância da função de auto-correlação em cada sub-banda (A2, D1 e D2).
- Razão entre o coeficiente mínimo e máximo de cada sub-banda (A2, D1 e D2).

O segundo grupo é formado por 11 características, em que 10 das 11 características são as mesmas do primeiro grupo, e a décima primeira característica é o tempo do último intervalo RR.

Os autores utilizaram 21 registros do banco de dados de arritmia do MIT-BIH, totalizando 11600 batimentos, e implementaram um classificador para 6 tipos de batimentos, sendo eles o batimento normal (N), o *Left bundle branch block beat* (L), o *Right bundle branch block beat* (R), a contração ventricular prematura (V), o batimento atrial prematuro (A) e batimento de marcapasso (/). Vamos utilizar o método proposto por Yu e Chen [3] para os mesmos registros já mencionados na introdução (Seção 1) e os mesmos tipos de batimentos (N, A, V, R) visando facilitar a comparação dos mesmos.

3.1 Classificação com rede neuronal probabilística

Uma rede neuronal probabilística é um tipo especial de *radial basis-function network*. A arquitetura desta rede pode ser ilustrada pela Figura 8. Ela consiste em um camada de entrada, uma camada chamada radial basis layer e uma chamada *competitive layer*. A camada de entrada é apenas uma camada de distribuição, ou seja, nenhum cálculo é feito. A camada *radial basis layer* computa a distância entre os vetores de entrada de teste para os vetores de entrada de treino e produz um vetor em que os elementos indicam quão próximo os elementos de entrada do teste estão dos elementos de entrada do treino. Já a segunda camada, a *competitive layer*, soma essas contribuições para cada classe para produzir um vetor de probabilidades. Finalmente, uma função na saída (*competitive transfer function*), pega o valor máximo destas probabilidades e produz um vetor com o valor 1 na posição referente à classe de maior probabilidade e zero para as outras. Em geral, redes neuronais probabilísticas tem o tempo de treino menor que o das outras arquiteturas, como as MLPs, mas em contra-partida elas precisam de mais neurônios em suas camadas escondidas, assim é preciso um número maior de vetores para o treinamento.

Network Architecture

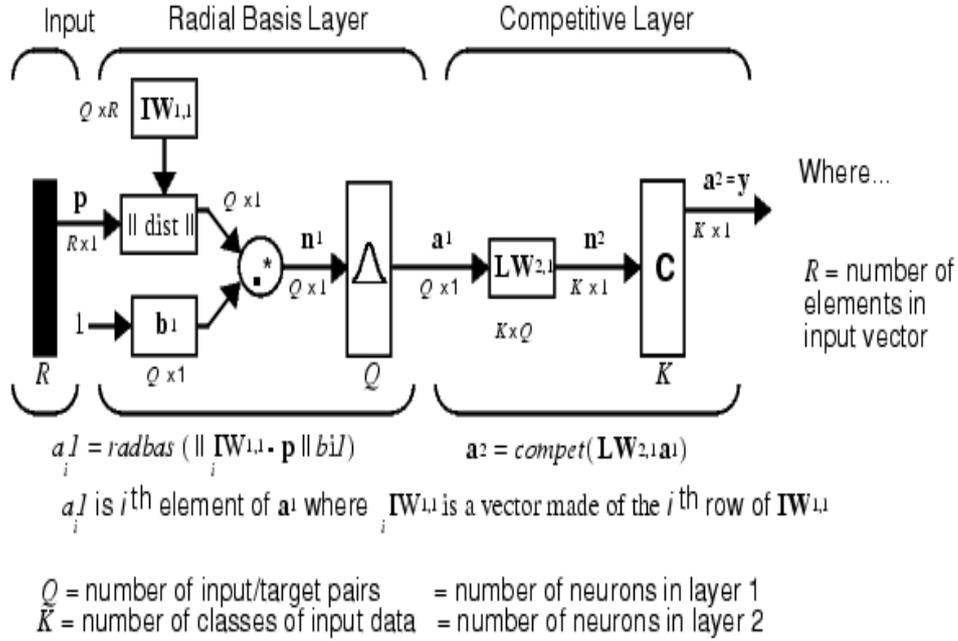


Figura 8: Arquitetura de uma rede neuronal probabilística

Tabela 1: Matriz de confusão para grupo 1

				Precisão(%)
90	0	0	0	-
17	57	9	7	-
0	0	87	3	-
0	3	0	87	-
-	-	-	-	89.16

3.2 Primeiro grupo

Para o primeiro grupo, foram calculadas 10 características para cada vetor de entrada. Assim, foi utilizado uma matriz 90x10 como entrada para o treino e um vetor de classificação de 90x1 para o treino. O restante dos dados foi utilizado no teste (90 vetores para cada classe). Os resultados obtidos podem ser visto na Tabela abaixo.

3.3 Segundo grupo

Para o segundo grupo foram utilizadas 11 características, em que a décima primeira característica é relativa ao ritmos cardíaco. Com a inclusão desta característica, a precisão foi significativamente melhorada.(Ver Tabela 2)

Tabela 2: Matriz de confusão para grupo 2

				Precisão(%)
87	3	0	0	-
7	70	12	1	-
0	2	88	0	-
0	0	0	90	-
-	-	-	-	93.05

3.4 Classificação com MLP

Os mesmo conjunto de dados foi utilizado para uma rede MLP. É possível notar que o resultado para MLP foi superior ao obtido pela rede probabilística (ver Figura 9 e Figura 10). Este resultado pode ser devido ao fato de que as redes neurais probabilísticas necessitam de um número maior de vetores para treinamento.

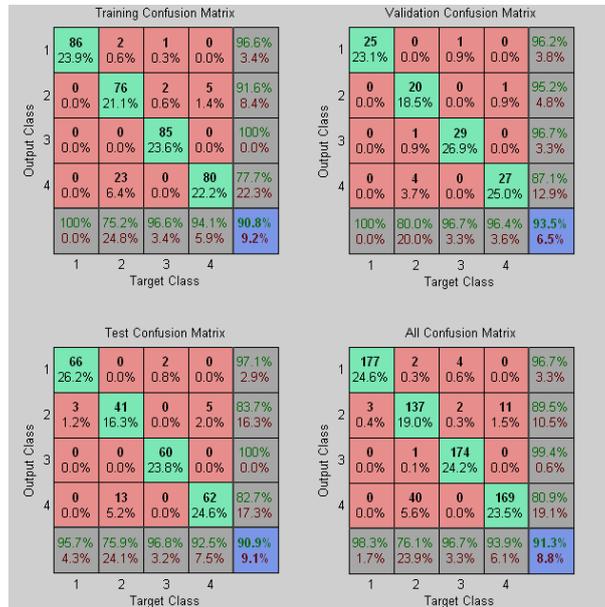


Figura 9: Matriz de confusão para o primeiro grupo de características

4 Método proposto por Song et al, 2005

Song et al[2] propuseram um método para classificação de arritmias no sinal de ECG baseado em *Support Vector Machine* (SVM).

Vinte e uma características foram utilizadas, sendo que 19 foram extraídas diretamente de coeficientes da transformada wavelet, em várias sub-bandas (coeficientes do sinal de detalhe dos níveis 4 a 7) e as outras duas características representam informação do ritmo cardíaco, calculadas da seguinte forma:

$$valor = \begin{cases} 1 & \frac{1}{R_i} \\ 2 & \frac{1}{R_{i+1}} \end{cases} \quad (1)$$

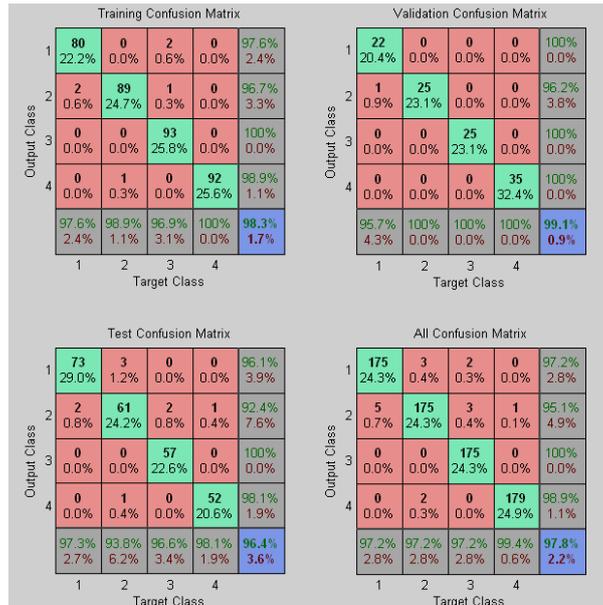


Figura 10: Matriz de confusão para o segundo grupo de características

Tabela 3: Precisão dos classificadores SVM para função de kernel quadrática

Batimento detectado	Precisão
N	99.16%
A	96.94%
V	98.61%
R	99.44%

Considerando amostragem a 360Hz, o valor de K foi igual a 300. Para a extração das características, foi utilizado uma janela de 400ms em torno do pico R, ou seja 144 amostras no total.

4.1 Toolbox de bioinformática do Matlab

Com o Toolbox de Bioinformática do Matlab, foram contruídos 4 classificadores baseados em SVM. Cada classificador foi projetado para detectar uma classe em específico (N, A, V e R) contra todas as outras. Para a classificação das quatro classes, a estratégia "Um-Contra-Todos" foi implementada. A Tabela 3 exibe a taxa de acerto dos classificadores SVM para uma função de kernel quadrática, já a Tabela 4 exibe a taxa para classificadores com função radial (RBF), que é a função de kernel utilizada pelo artigo em questão. O tempo de treinamento para o classificador SVM com função de kernel RBF é significativamente inferior, assim como a Precisão.

4.2 Libsvm

Com a biblioteca libsvm foi possível configurar alguns parâmetros extras do classificador SVM, como a constante C (*margin-losses trade-off*). O melhor resultado foi

Tabela 4: Precisão dos classificadores SVM para função de kernel RBF

Batimento detectado	Precisão
N	95.83%
A	93.61%
V	93.88%
R	99.16%

obtido com função de kernel quadrática e constante $C = 10$. A precisão foi de 95.55% (344/360). Já a precisão para uma função RBF e $C = 10$ foi de 87.5% (315/360).

5 Conclusão

O clasificador SVM com função de kernel quadrática teve o melhor desempenho, em termos de precisão, mas o tempo para treinamento é significativamente superior ao das redes neuronais e mesmo um classificador SVM com função de kernel RBF. Um trabalho futuro seria analisar a performance computacional do classificador SVM em uma aplicação de tempo real, já que uma vez que o classificador foi construído, o tempo de treino não trará mais impacto.

Pelo segundo método [3], enxergamos a importância da seleção apropriada das características. A inclusão de apenas 1 característica (com informação do ritmo cardíaco) ofereceu uma melhora significativa nos resultados finais. Assim, a informação sobre o ritmo é fundamental para alguns tipos de arritmias.

Referências

- [1] I. Güler and E. D. Übeyli. ECG beat classifier designed by combined neural network model. *Pattern Recognition*, 38(2):199–208, 2005.
- [2] M. H. Song, J. Lee, S. P. Cho, K. J. Lee, and S. K. Yoo. Support vector machine based arrhythmia classification using reduced features. *International Journal of Control, Automation, and Systems*, 3(4):509–654, 2005.
- [3] S. Yu and Y. Chen. Electrocardiogram beat classification based on wavelet transformation and probabilistic neural network. *Pattern Recognition Letters*, 28(10):1142–1150, 2007.