6. Análise dos Resultados

Conforme descrito no capítulo 5, todos os modelos de classificadores implementados neste trabalho foram avaliados em função do número p de componentes principais. Este número foi usado como parâmetro de entrada dos experimentos com a finalidade de representar as imagens originais de 4096 pixels em vetores de p características. Para determinar o valor máximo de p, computou-se o erro residual médio das componentes principais - de acordo com a fórmula (5.2.1.3) do capítulo 5 - para um total de 25 rodadas, utilizando diferentes conjuntos de treinamento e de teste. O gráfico da figura 6.1 abaixo mostra os resultados destes cálculos.

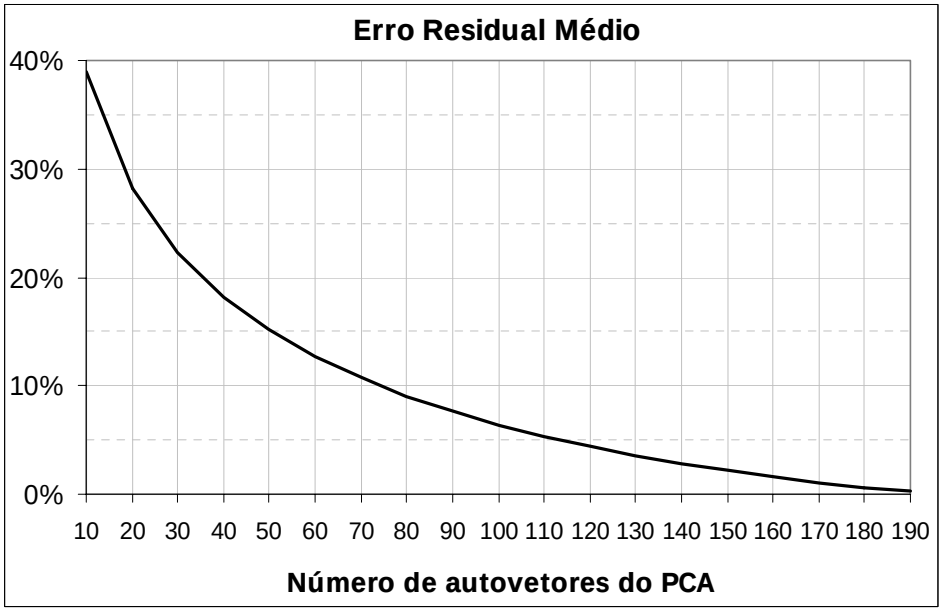

Figura 6.1 – Gráfico do erro residual médio de cada componente principal

Pode-se verificar pelo gráfico da figura 6.1 que o erro residual médio decai exponencialmente à medida que cresce o número de autofaces. Observa-se, ainda, que para um número de autofaces maior ou igual a 100 tem-se um erro residual relativamente pequeno, em torno de 5%.

Foi definido o valor máximo do parâmetro p como igual a 100. Os experimentos foram realizados avaliando a taxa de reconhecimento de cada classificador para 10 valores distintos de componentes principais: 10; 20; 30; 40; 50; 60; 70; 80; 90 e 100.

Inicialmente, os resultados dos classificadores de cada tipo foram comparados entre si. Foram confrontados os classificadores de distância, os classificadores RBF para os diferentes algoritmos de aprendizado, os classificadores MDA com número de componentes discriminantes distintos, e o classificador MPM para diversos valores do fator de regressão. Em seguida, os classificadores com maiores taxas de reconhecimento de cada tipo foram comparados entre si. A seguir, esses resultados são apresentados.

6.1 Os Classificadores de Distância

A figura 6.2 apresenta a taxa de reconhecimento média para os classificadores de distância Euclideana e de Mahalanobis em função do número de autofaces.

Verifica-se que para um número de autovetores menor do que 40, ambos os classificadores apresentam desempenho bastante próximo, com uma leve superioridade do classificador de distância Euclideana. No entanto, a medida que se aumenta o número de autofaces e, consequentemente, a variância descrita pelas componentes principais do PCA, o classificador de Mahalanobis apresenta melhor performance.

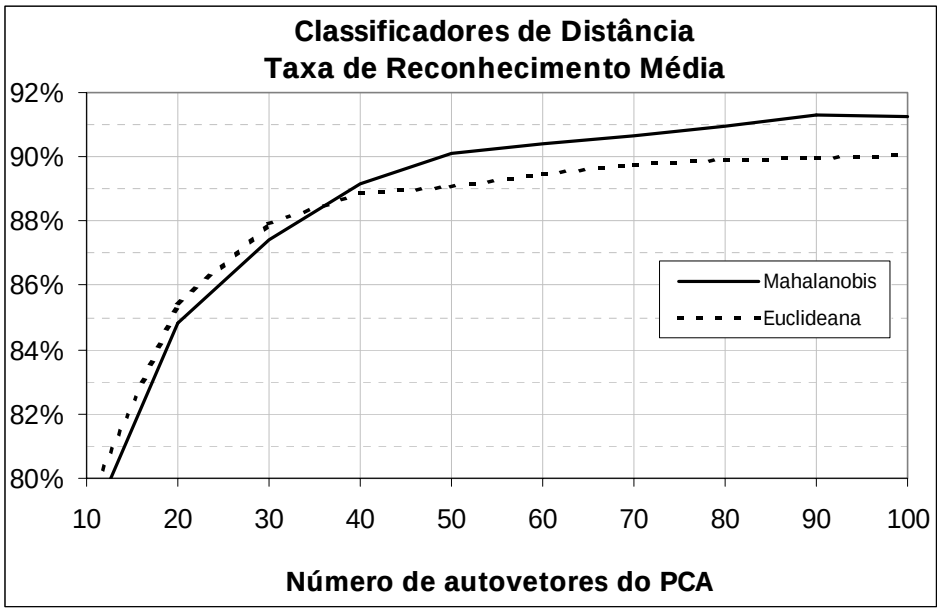

Figura 6.2 – Gráfico da Taxa de Reconhecimento Média dos Classificadores de Distância

Estes resultados podem ser explicados pelo fato de que, quando se tem um número de componentes principais menor do que o número de grupos a classificar, estas componentes descrevem as maiores diferenças ou variações de todas as amostras em questão. Quando o número de autovetores do PCA é igual ao número de grupos a discriminar e, admitindo, como é o caso, que estes grupos estejam relativamente separados, cada autovetor passa a descrever uma classe, representando-a de forma única. No entanto, quando o número de componentes principais passa a ser maior do que o número de classes, os autovetores do PCA começam a descrever diferenças ou variações entre as classes. Estas variações, que caracterizam as formas de cada grupo, precisam ser consideradas nos cálculos de distância para uma melhor classificação dos dados. Por isso, verifica-se que para um número de autofaces maior do que 40 o classificador de distância de Mahalanobis passa a obter uma taxa de reconhecimento média substancialmente melhor do que a do classificador Euclideano.

Entre os classificadores de distância avaliados, o classificador de Mahalanobis apresentou melhor taxa de reconhecimento, atingindo um valor máximo de 92% para 90 componentes principais.

6.2 Os Classificadores RBF

Os classificadores RBF apresentam um desempenho superior aos classificadores de distância. Estes classificadores consistem de duas redes neurais RBF treinadas de acordo com os dois algoritmos de aprendizado discutidos no capítulo 5: o algoritmo *Forward Selection*(FS) ou Método Ortogonal dos Mínimos Quadrados e o algoritmo *Mixture Model*(MM) ou Método de Gaussianas Misturadas. No caso da RBF com algoritmo de aprendizado MM, obteve-se mais de uma curva de desempenho variando o número de neurônios Q da camada escondida de acordo com os seguintes valores: 70; 80; 90; 100 e 110. A partir de 110 neurônios a rede RBF MM não apresentou melhoras significativas de resultados. A curva relativa à RBF FS corresponde a uma rede neural com aproximadamente 100 neurônios na camada escondida. O gráfico da figura 6.3 mostra as taxas médias de reconhecimento desses classificadores em função do número de autofaces.

Observa-se no gráfico da figura 6.3 que o algoritmo de aprendizado MM propicia à rede RBF um desempenho bem melhor do que o algoritmo de aprendizado FS, mesmo para um número de neurônios bem menor, igual a 70 por exemplo. Verifica-se, ainda, que para um número de autofaces entre 30 e 60, as redes RBF MM apresentam as melhores taxas de reconhecimento, atingindo uma média de 95,5% para 50 componentes principais e 110 neurônios na camada escondida.

Portanto, entre as redes RBF analisadas o classificador de melhor desempenho é aquele treinado com o algoritmo de aprendizado *Mixture Model* com 110 neurônios na camada escondida.

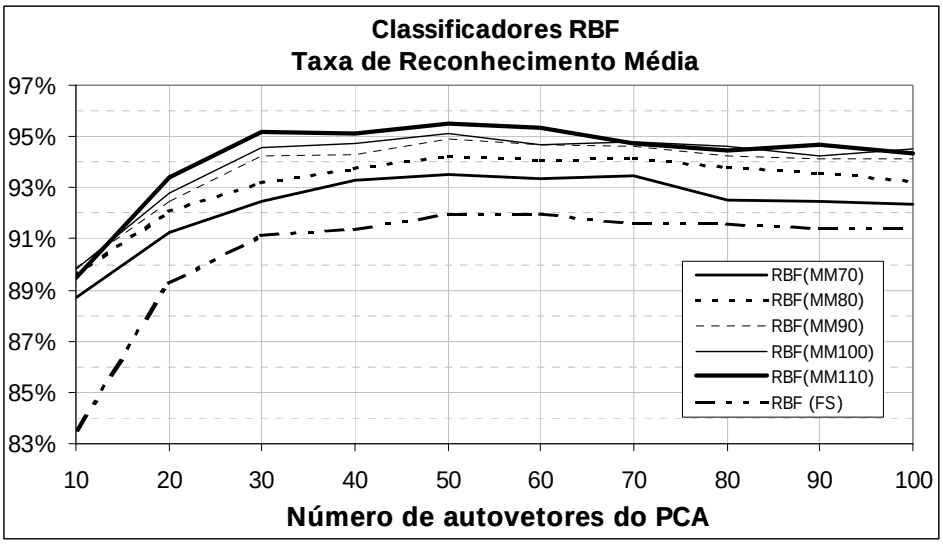

Figura 6.3 – Gráfico da Taxa de Reconhecimento Média dos Classificadores RBF

6.3 Os Classificadores MDA

Nos experimentos relativos ao classificador MDA variou-se o número m de componentes discriminantes. Este número assumiu 4 valores distintos: 10; 20; 30 e 39. Como na aplicação em questão existem 40 indivíduos ou grupos distintos, o número máximo possível de componentes discriminantes é igual a 39. Cada número de componentes discriminantes gerou um classificador MDA, resultando, pois, em 4 curvas de desempenho que mostram as taxas médias de reconhecimento em função do número de autofaces. Devido aos problemas de inversibilidade da matriz intra-grupos $\mathbf{W}$ discutidos no capítulo 5, as curvas para os classificadores MDA foram avaliadas para um número de componentes

principais maior ou igual ao número de componentes discriminantes. Isto fez com que, por exemplo, o classificador MDA com 30 componentes discriminantes tivesse sua primeira taxa de reconhecimento calculada a partir de um número de autofaces igual a 30 e não igual a 10 como no caso dos demais tipos de classificadores. As curvas de desempenho desses quatro classificadores MDA podem ser vistas no gráfico da figura 6.4 .

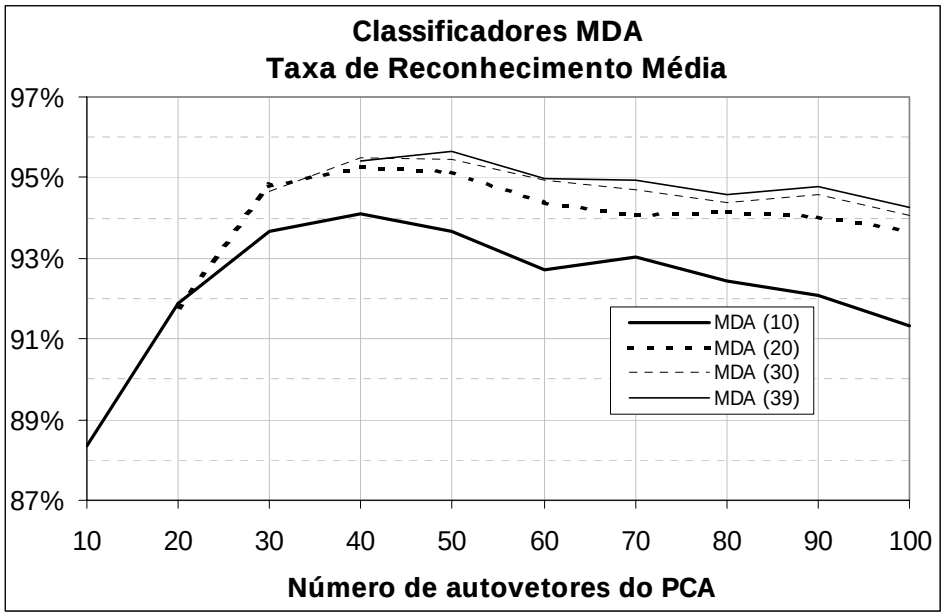

Figura 6.4 – Gráfico da Taxa de Reconhecimento Média dos Classificadores MDA

Pode-se observar que os classificadores MDA possuem melhores taxas de reconhecimento médias para um número de autofaces entre 30 e 60, apresentando um comportamento semelhante aos classificadores RBF discutidos anteriormente. Constata-se, também, que o número de componentes discriminantes considerado é um importante fator de desempenho para este tipo de classificador, mostrando que para 10 componentes discriminantes tem-se as piores taxas de reconhecimento enquanto que para 39 componentes discriminantes tem-se os melhores resultados.

O gráfico da figura 6.4 mostra ainda que o classificador MDA com 39 componentes discriminantes atinge uma taxa média máxima de reconhecimento de 95,7% para um número

de autofaces igual 50, resultado bastante próximo ao classificador RBF de melhor desempenho.

6.4 Os Classificadores MPM

Para avaliar o desempenho do novo classificador MPM proposto neste trabalho, variou-se o valor do fator de regressão a conforme descrito no capítulo 5. Este parâmetro assumiu 5 valores distintos: 0,1; 0,3; 0,5; 0,7; 0,9. De forma análoga ao classificador MDA, para cada valor de a construiu-se um classificador MPM, obtendo-se 5 curvas de desempenho que apresentam as taxas médias de reconhecimento em função do número de autofaces, conforme mostra a figura 6.5.

Constata-se, pelo gráfico da figura 6.5, que o desempenho deste classificador é de um modo geral muito superior ao de todos os demais classificadores considerados neste trabalho. Pode-se observar que para um número de autofaces entre 30 e 50, independentemente do valor do fator de regressão utilizado, tem-se uma taxa média de reconhecimento maior do que 96%, não ultrapassando os 97%. Verifica-se que o classificador MPM de melhor desempenho corresponde a um fator de regressão igual 0,7, apresentando uma taxa média máxima de reconhecimento igual a 96,9% com 40 componentes principais.

Depois de avaliar separadamente cada tipo de classificador e identificar as melhores configurações de cada um deles, foram comparados os resultados dos melhores classificadores de cada tipo, desconsiderando nesta avaliação os classificadores de distância por apresentarem, como visto, taxas médias de reconhecimento bastante inferiores aos demais modelos avaliados.

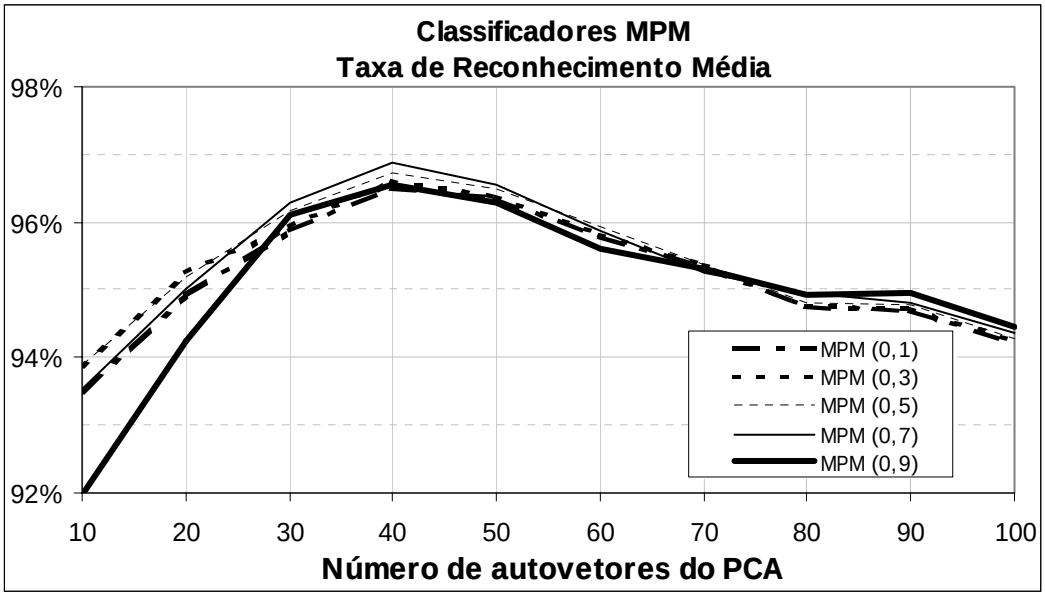

Figura 6.5 – Gráfico da Taxa de Reconhecimento Média dos Classificadores MPM

A figura 6.6 mostra as taxas médias de reconhecimento para o melhor classificador RBF com algoritmo de aprendizado *Mixture Model*(MM) e 110 neurônios na camada escondida, o melhor classificador MDA com 39 componentes discriminantes e também o melhor classificador MPM com fator de regressão igual a 0,7.

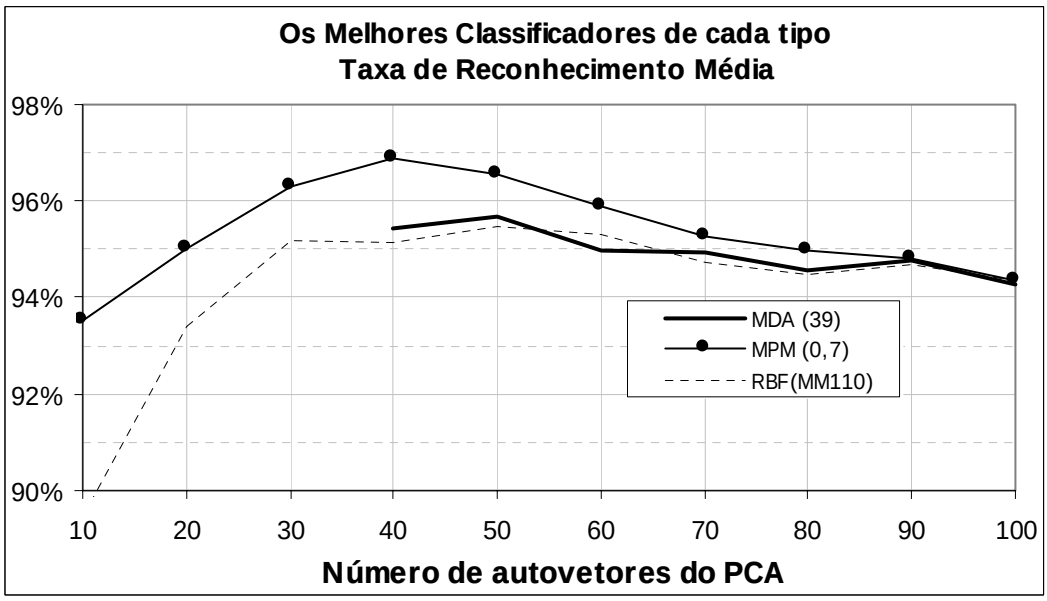

Figura 6.6 – Gráfico da Taxa de Reconhecimento Média dos melhores Classificadores de cada tipo

Pode-se certificar pelo gráfico da figura 6.6 que o classificador MPM apresentou as melhores taxas de reconhecimento em todos os experimentos, independentemente do número de autovetores do PCA considerado. Comprova-se que o classificador MPM com fator de regressão 0,7 atingiu uma taxa média de reconhecimento máxima de 96,9% para um menor número de autofaces – igual a 40 – enquanto que o melhor classificador RBF e o melhor classificador MDA atingiram, respectivamente, uma taxa média máxima de reconhecimento de 95,5% e 95,7% para 50 componentes principais.

Outro aspecto importante revelado pelos experimentos é mostrado pelo gráfico da figura 6.7. Este gráfico apresenta o desvio padrão da taxa de reconhecimento calculada para as 25 rodadas de cada número de autovetores do PCA. Estes cálculos indicam quão sensíveis são os resultados de cada classificador à escolha dos conjuntos de treinamento e teste.

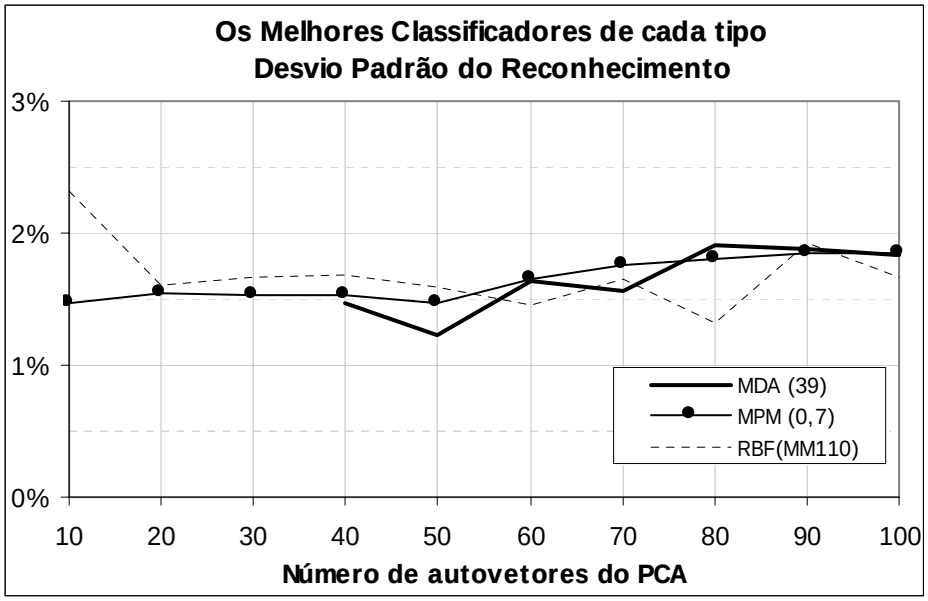

Figura 6.7 – Gráfico do Desvio Padrão do Reconhecimento dos melhores Classificadores de cada tipo

O gráfico da figura 6.7 mostra que todos os três classificadores apresentam, a partir de um número de autovetores maior do que 20, desvios padrões similares compreendidos entre 1% e 2%. O melhor resultado é de 1.2% obtido pelo classificador MDA para 50 autofaces. Para um número de autofaces menor do que 40, o classificador MPM apresenta um desvio padrão aproximadamente constante de 1.5%, resultados melhores do que o classificador RBF. Quando o número de autovetores do PCA aumenta, os classificadores MDA e RBF se confundem na apresentação dos melhores resultados.

Como uma análise complementar à figura 6.7, a taxa de reconhecimento absoluta mínima e máxima computada para as 25 rodadas de cada número de autovetores do PCA e para cada classificador são mostradas respectivamente nas figuras 6.8 e 6.9.

Ambos os gráficos das figuras 6.8 e 6.9 revelam a superioridade do classificador MPM com relação aos demais classificadores analisados também quanto a sensibilidade à escolha do conjunto de treinamento.

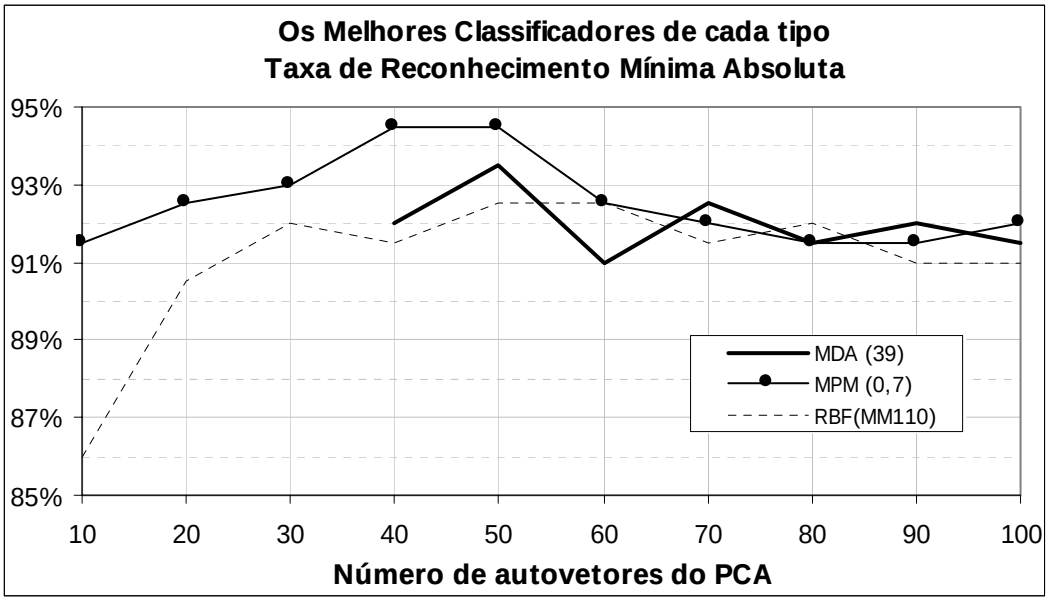

Figura 6.8 – Gráfico da Taxa de Reconhecimento Mínima dos melhores Classificadores de cada tipo

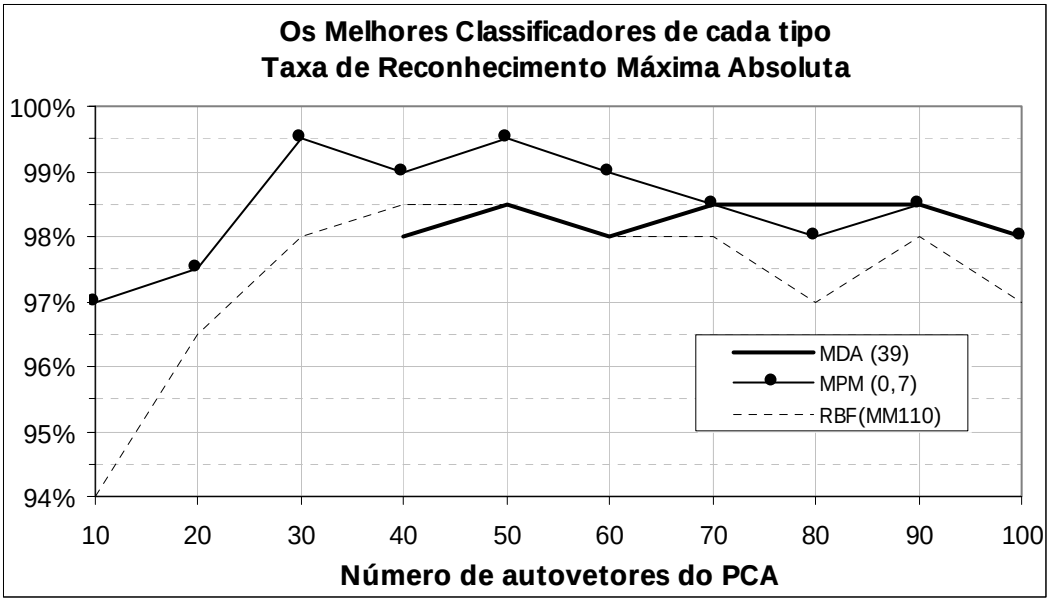

Figura 6.9 – Gráfico da Taxa de Reconhecimento Máxima dos melhores Classificadores de cada tipo

Esta superioridade pode ser também percebida pelo gráfico de barras da figura 6.10. Cada barra corresponde ao número de vezes que, para cada um dos 25 sorteios do conjunto de treinamento e teste, um classificador obteve a maior taxa de reconhecimento absoluta com relação aos demais classificadores, em função do número de autofaces - como houve empates de resultados, a soma dos valores das barras de cada modelo não necessariamente é igual a 25. Pode-se constatar que exceto para 90 autofaces o classificador MPM foi o melhor classificador para todos os sorteios realizados.

O gráfico da figura 6.9 apresenta, ainda, um outro resultado interessante. Dependendo da escolha do conjunto de treinamento, o classificador MPM pode chegar a ter uma taxa de reconhecimento absoluta de 97% para apenas 10 componentes principais, bem como uma taxa de 99.5% para 30 autofaces. É importante ressaltar que para o banco de faces ORL utilizado neste trabalho, tinha-se como maior taxa de reconhecimento absoluta até então atingida o valor de 97.5%, obtida pelo trabalho de [Lawr97].

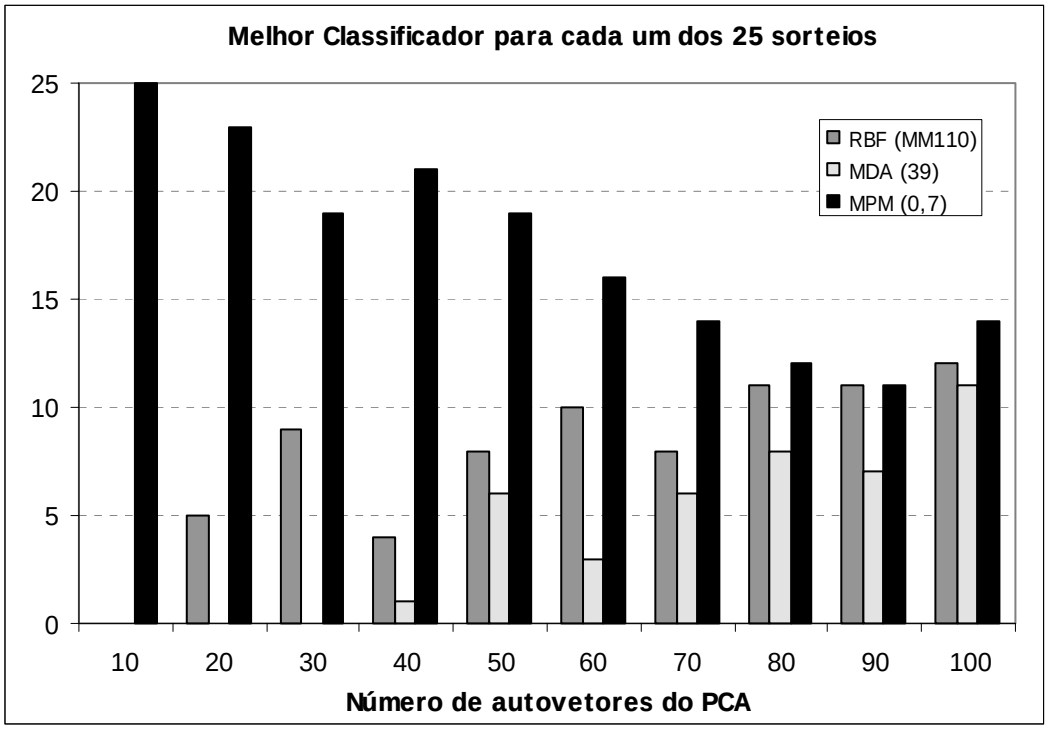

Figura 6.10 – Gráfico do Melhor Classificador para cada um dos 25 sorteios do conjunto de treinamento e teste

Como comentário final, cabe enfatizar que os experimentos realizados apontaram o classificador proposto neste trabalho, o classificador MPM de matrizes de covariância misturadas, entre todos os classificadores considerados como o de melhor desempenho para o problema de reconhecimento automático de faces.