



[12] 发明专利说明书

专利号 ZL 02824006.5

[45] 授权公告日 2007 年 2 月 28 日

[11] 授权公告号 CN 1302437C

[22] 申请日 2002.12.3 [21] 申请号 02824006.5

[30] 优先权

[32] 2001.12.3 [33] US [31] 60/336,947

[32] 2001.12.3 [33] US [31] 60/337,022

[32] 2002.7.22 [33] US [31] 10/201,429

[86] 国际申请 PCT/JP2002/012649 2002.12.3

[87] 国际公布 WO2003/049033 英 2003.6.12

[85] 进入国家阶段日期 2004.6.3

[73] 专利权人 本田技研工业株式会社

地址 日本东京都

[72] 发明人 杨明玄

[56] 参考文献

CN1184542A 1998.6.10

JP2001273495 A 2001.10.5

审查员 唐田田

[74] 专利代理机构 中原信达知识产权代理有限责
任公司

代理人 钟强 谷慧敏


权利要求书 6 页 说明书 20 页 附图 7 页

[54] 发明名称

使用 Kernel Fisher faces 的面部识别的方法和
系统

[57] 摘要

一种面部识别系统和方法从输入空间投射输入面部图像和参考面部图像集到高维数特征空间，以获得面部图像的更多表示特征。计算输入面部图像和参考面部图像的 Kernel Fisherfaces，并将其用于投射输入面部图像和参考面部图像到比输入空间维数低的面部图像空间和高维数特征空间。输入面部图像和参考面部图像被表示为面部图像空间内的点，且输入面部点和每个参考图像点之间的距离被用于确定输入面部图像是否相像于参考面部图像的特定面部图像。



1. 一种在第一维数的输入空间中表示对应于第一向量集的参考面部图像集的方法，该方法包括：

5 使用投射函数来投射第一向量到第二维数的高维数特征空间中，以产生高维数特征空间内的第二向量集，该第二维数具有比第一维数高的维数；

 产生用于第二向量的 Kernel Fisherfaces；

 根据第二向量和 Kernel Fisherfaces 来在第三维数的面部图像空间中产生第三向量集，该第三向量对应于面部图像空间内的参考面部图像点，并且第三维数具有比第一维数和第二维数低的维数；以及

 将输入面部图像识别为对应于参考面部图像集内的特定面部图像，输入面部图像由输入空间内的至少第四向量来表示，识别输入空间的步骤包括：

15 使用投射函数来投射该第四向量到高维数特征空间，以产生高维数特征空间内的第五向量；

 根据第五向量和 Kernel Fisherfaces 来在面部图像空间内产生第六向量，该第六向量对应于面部图像空间内的输入面部图像点；

 计算面部图像空间内输入面部图像点和每个参考面部图像点之间的距离；以及

20 响应于确定所计算距离的最小值，来将输入面部图像识别为对应于与该最小距离相对应的参考面部图像。

2. 如权利要求 1 的方法，其中将参考面部图像分组为至少两类，第一、第二和第三向量分别分布在输入空间、高维数特征空间和面部图像空间内的至少两个群中，以及产生 Kernel Fisherfaces，包括：

 产生投射第二向量到面部图像空间的向量，从而在面部图像空间内第三向量群之间的变化基本上被最大化，而第三向量每个群之内的变化基本上被最小化。

3. 如权利要求 2 的方法，其中第三向量群之间的变化由分类间散布矩阵表示，且每个第三向量群之内的变化由分类内散布矩阵表示。

5 4. 如权利要求 3 的方法，其中 Kernel Fisherfaces 投射第二向量到面部图像空间，从而分类间散布矩阵和分类内散布矩阵之间的比率基本上被最大化。

10 5. 如权利要求 3 的方法，其中，根据 $S_w^{\circ} = S_w^{\circ} + \epsilon I$ 修正分类内散布矩阵，其中 S_w° 表示分类内矩阵，而 I 是单位矩阵，该单位矩阵的维数与 S_w° 相同，并且 ϵ 是小实数。

6. 一种将输入面部图像识别为对应于参考面部图像集内特定面部图像的方法，参考面部图像由第一向量集表示，且输入面部图像由在第一维数的输入空间内的至少第二向量表示，该方法包括：

15 使用投射函数 $\Phi(x)$ 来投射第一向量到第二维数的高维数特征空间中，以产生高维数特征空间内的第三向量集，该第二维数具有比第一维数高的维数；

产生用于第三向量的 Kernel Fisherfaces；

20 根据第三向量和 Kernel Fisherfaces 来在第三维数面部图像空间中产生第四向量集，该第四向量对应于面部图像空间内的参考面部图像点，并且第三维数具有比第一维数和第二维数低的维数；

使用投射函数 $\Phi(x)$ 来投射第二向量到高维数特征空间，以产生高维数特征空间内的第五向量；

25 根据第五向量和 Kernel Fisherfaces 来在面部图像空间内产生第六向量，该第六向量对应于面部图像空间内的输入面部图像点；

计算面部图像空间内输入面部图像点和每个参考面部图像点之间的距离；以及

响应于确定所计算距离的最小值，来将输入面部图像识别为对应于与该最小距离相对应的参考面部图像。

7. 如权利要求 6 的方法, 其中参考面部图像被分组为至少两个分类, 第一、第三和第四向量分别分布在输入空间、高维数特征空间和面部图像空间中的至少两个群中, 并产生 Kernel Fisherfaces, 包括:

5 产生投射第三向量到面部图像空间的向量, 从而在面部图像空间内第四向量群之间的变化基本上被最大化, 而第四向量每个群之内的变化基本上被最小化。

8. 如权利要求 7 的方法, 其中第四向量群之间的变化由分类间散布矩阵表示, 且第四向量每个群之内的变化由分类内散布矩阵表示。

10

9. 如权利要求 8 的方法, 其中 Kernel Fisherfaces 投射第三向量到面部图像空间, 从而分类间散布矩阵和分类内散布矩阵之间的比率基本上被最大化。

15

10. 如权利要求 8 的方法, 其中, 根据 $S_w^* = S_w^* + \epsilon I$ 修正分类内散布矩阵, 其中 S_w^* 表示分类内矩阵, 而 I 是单位矩阵, 该单位矩阵的维数与 S_w^* 相同, 并且 ϵ 是小实数。

20

11. 如权利要求 6 的方法, 其中投射函数 $\Phi(x)$ 满足以下关系:

$$k(x,y) = \Phi(x) \cdot \Phi(y)$$

其中 $k(x,y)$ 是 kernel 函数, $\Phi(x) \cdot \Phi(y)$ 是投射函数 $\Phi(x)$ 和 $\Phi(y)$ 的点积, 以及 x 和 y 是实数变量。

25

12. 如权利要求 11 的方法, 其中 kernel 函数是多项式 kernel 函数。

13. 如权利要求 11 的方法, 其中 kernel 函数是高斯 kernel 函数。

14. 如权利要求 6 的方法, 其中产生第四向量集包括: 执行在第三向量与高维数特征空间内的 Kernel Fisherfaces 之间的点积运算。

15. 如权利要求 6 的方法，其中产生第六向量包括：执行在第五向量与高维数特征空间内的 Kernel Fisherfaces 之间的点积运算。

16. 如权利要求 6 的方法，其中该距离是欧几里得距离。

5

17. 一种面部识别系统，用于将输入面部图像识别为对应于参考面部图像集内特定面部图像的方法，参考面部图像由第一向量集表示，且输入面部图像由在第一维数的输入空间内的至少第二向量表示，该面部识别系统包括：

10 高维数特征空间投射模块，其用于使用投射函数 $\Phi(x)$ 来投射第一向量和第二向量到第二维数的高维数特征空间中，以分别产生第三向量和第四向量，该第二维数具有比第一维数高的维数；

Kernel Fisherfaces 模块，其用于计算第三向量的 Kernel Fisherfaces；

15 面部图像投射模块，其用于使用 Kernel Fisherfaces 来在第三维数的面部图像空间中从第三向量产生第五向量集，和从第四向量中产生第六向量，该第五向量对应于面部图像空间内的参考面部图像点，且该第六向量对应于面部图像空间内的输入面部图像点，并且该第三维数具有比第一维数和第二维数低的维数；以及

20 距离计算模块，其用于计算面部图像空间内输入面部图像点和每个参考面部图像点之间的距离。

18. 如权利要求 17 的面部识别系统，进一步包括：存储模块，其用于存储 Kernel Fisherfaces 和第五向量。

25

19. 如权利要求 17 的面部识别系统，其中距离计算模块确定所计算距离的最小值，并将输入面部图像识别为相像于与该最小距离相对应的参考面部图像。

30 20. 如权利要求 17 的面部识别系统，其中参考面部图像能够被分

5 组为至少两个分类，第一、第三和第五向量分别分布在输入空间、高维数特征空间和面部图像空间中的至少两个群中，并且 Kernel Fisherfaces 模块通过得出投射第三向量到面部图像空间的向量来计算 Kernel Fisherfaces，从而在面部图像空间内第五向量群之间的变化基本上被最大化，而每个第五向量群之内的变化基本上被最小化。

21. 如权利要求 20 的面部识别系统，其中第五向量群之间的变化由分类间散布矩阵表示，且每个第五向量群之内的变化由分类内散布矩阵表示。

10

22. 如权利要求 21 的面部识别系统，其中 Kernel Fisherfaces 投射第三向量到面部图像空间，从而分类间散布矩阵和分类内散布矩阵之间的比率基本上被最大化。

15 23. 如权利要求 21 的面部识别系统，其中，根据 $S_{w^{\circ}} = S_w^{\circ} + \epsilon I$ 修正分类内散布矩阵，其中 S_w° 表示分类内矩阵，而 I 是单位矩阵，该单位矩阵的维数与 S_w° 相同，并且 ϵ 是小实数。

20 24. 如权利要求 17 的面部识别系统，其中投射函数 $\Phi(x)$ 满足以下关系：

$$k(x,y) = \Phi(x) \cdot \Phi(y)$$

其中 $k(x,y)$ 是 kernel 函数， $\Phi(x) \cdot \Phi(y)$ 是投射函数 $\Phi(x)$ 和 $\Phi(y)$ 的点积，以及 x 和 y 是实数变量。

25 25. 如权利要求 24 的面部识别系统，其中 kernel 函数是多项式 kernel 函数。

26. 如权利要求 24 的面部识别系统，其中 kernel 函数是高斯 kernel 函数。

27. 如权利要求 17 的面部识别系统, 其中通过执行在第三向量与高维数特征空间内的 Kernel Fisherfaces 之间的点积运算来产生第五向量集。

5 28. 如权利要求 17 的面部识别系统, 其中通过执行在第四向量与高维数特征空间内的 Kernel Fisherfaces 之间的点积运算来产生第六向量。

29. 如权利要求 17 的面部识别系统, 其中该距离是欧几里得距离。

使用 Kernel Fisherfaces 的面部识别 的方法和系统

5 相关申请交叉参考

本申请要求在 2001 年 12 月 3 日申请的名称为“Kernel Methods for Face Recognition”的美国临时专利申请 No.60/336,974, 和 2001 年 12 月 3 日申请的名称为“Face Recognition Using Kernel Methods”的美国临时专利申请 No.60/337,022, 以及在 2002 年 7 月 22 日申请的名称为
10 “Face Recognition Using Kernel Fisherfaces”的美国专利申请 No.10/201,429 的优先权。

技术领域

本发明通常涉及面部识别, 更具体的, 涉及使用 Kernel Fisher 线性区别分析或 Kernel Fisherfaces 的面部识别。
15

背景技术

近来面部识别技术受到增强的关注, 原因是它可用在例如监视、安全、广告等各种应用中。然而, 先前的尝试开发有效面部识别系统是不成功的, 因为在先前面部识别系统中使用的计算机和算法不能有效处理面部识别所固有包含的大量数据和复杂计算。这些先前尝试通常使用不能说明面部图像中内在结构信息的简单特征表示。只有可
20 通过使用例如高阶统计的高级方法才能编码这些内在结构信息。此外, 当在各种照明条件下照亮面部图像时, 先前的面部识别系统不能工作良好。
25

近来, 例如主分量分析 (Principal Component Analysis) (PCA) 和 Fisher 线性判别式 (Fisher Linear Discriminant) (FLD) 的线性子空间方法被应用到面部识别, 得到了令人瞩目的结果。PCA 和 FLD 利用面部识别中基本的特征值问题, 并且因此从它们在输入空间中的图像采
30

样中归纳出面部图像的较低维数表示。这样，PCA 和 FLD 减少了数据量，从而减轻了面部识别中的计算负担。

使用 PCA 的面部识别系统的一个例子公开在 Turk 等的美国专利 No.Re.36,014 中。在此，该面部识别系统使用 PCA 来获得比输入空间维数低的多维空间中的面部图像表示。PCA 的使用能减少数据量以及面部识别的计算负担。

PCA 和 FLD 的缺点之一是，除了像素之间的相对位置外，面部图像的较低维数表示没有关于图像内像素之间关系的信息。即 PCA 或 FLD 内的较低维数表示是根据图像的二阶统计，即，像素中的按像素的 (pixelwise) 协方差，并不针对 (address) 例如三个或更多像素之间关系的高阶统计相关性。这样的在面部图像中的高阶相关性可以包括像素强度值之间的关系，例如在某边缘或某条曲线内的三个或更多像素之间的关系。高阶相关性通常具有面部图像的更有意义、更有代表性的特征，并能捕获用于面部识别的重要信息。PCA 和 FLD 不使用高阶统计相关性的原因之一是，它导致了巨大的计算负担。

在机器学习领域对使用高阶统计相关性作了一些研究。然而，在机器学习中使用的输入数据和面部识别中使用的面部图像非常各种。首先，机器学习中的数据是相对干净（没有多少噪声）且具有低维数，即，每个采样或数据点通常是具有低于 200 元素的短向量。

另一选择是，面部图像变化大，这就是面部识别难以实施的原因之一。其次，面部识别中的采样维数比机器学习的高得多，这样就导致了面部识别中的大量数据以及计算负担。例如，通常的 50X50 像素面部图像在每个采样中具有 2500 元素。因为这些原因，在机器学习领域使用高阶统计相关性所包含的算法以及数学和那些用在面部识别中的有本质的各种。因此，机器学习领域中用于使用高阶统计相关性的算法和数学不能被应用到面部识别中。

因此，必需有一种面部识别系统和方法，其可以处理具有广泛变化的面部图像以及大量的图像数据，从而可使用面部图像的高阶相关性来获得面部图像的更多表示特征，而不在该面部识别系统上引入大量计算负担。此外，需要一种面部识别系统，其在当将这些特征被投射（project）到较低维数面部图像空间时，能使用面部图像区别特征并使分类区别（class separation）最大化。

发明内容

本发明提供一种面部识别系统和方法，它们使用面部图像的更多表示和区别特征，而不引入巨大的计算负担。该面部识别系统从输入空间投射输入面部图像和参考面部图像集到高维数特征空间，从而获得面部图像的更多表示特征。算出参考面部图像的 Kernel Fisherfaces，并将其用于投射输入面部图像和参考面部图像到比输入空间维数低的面部图像空间和高维数特征空间。这样，获得了面部图像的表示和区别特征，并可将其用于面部识别中，而不引入大量计算负担。

当使用 Kernel Fisherfaces 投射时，输入面部图像和参考面部图像在较低维数面部图像空间中用向量表示。算出输入面部图像点和每个参考面部图像点之间的距离。本发明的面部识别系统和方法确定所计算距离中的最短距离。结果，当所计算的最短距离小于阈值时，确定输入面部图像相像于由对应于面部图像空间内最短距离的参考图像点之一所表示的特定面部图像。

通过在面部识别中使用 Kernel Fisher 线性判别式（Kernel Fisherfaces），能够简化在像素之间使用高阶相关性和区别图像内特征所包含的计算，同时在面部识别中获得并使用面部图像的更多表示和区别特征。

本发明可以多种形式体现，包括计算机程序产品，方法，和系统，

专用或通用计算装置或设备，在线服务或系统，用户接口等。

5 根据本发明的一个方面，提供了一种在第一维数的输入空间中表
示对应于第一向量集的参考面部图像集的方法，该方法包括：使用投
射函数来投射第一向量到第二维数的高维数特征空间中，以产生高维
数特征空间内的第二向量集，该第二维数具有比第一维数高的维数；
产生用于第二向量的 Kernel Fisherfaces；根据第二向量和 Kernel
Fisherfaces 来在第三维数的面部图像空间中产生第三向量集，该第三向
量对应于面部图像空间内的参考面部图像点，并且第三维数具有比第
10 一维数和第二维数低的维数；以及，将输入面部图像识别为对应于参
考面部图像集内的特定面部图像，输入面部图像由输入空间内的至少
第四向量来表示，识别输入空间的步骤包括：使用投射函数来投射该
第四向量到高维数特征空间，以产生高维数特征空间内的第五向量；
根据第五向量和 Kernel Fisherfaces 来在面部图像空间内产生第六向量，
15 该第六向量对应于面部图像空间内的输入面部图像点；计算面部图像
空间内输入面部图像点和每个参考面部图像点之间的距离；以及，响
应于确定所计算距离的最小值，来将输入面部图像识别为对应于与该
最小距离相对应的参考面部图像。

20 根据本发明的另一方面，提供了一种将输入面部图像识别为对应
于参考面部图像集内特定面部图像的方法，参考面部图像由第一向量
集表示，且输入面部图像由在第一维数的输入空间内的至少第二向量
表示，该方法包括：使用投射函数 $\Phi(x)$ 来投射第一向量到第二维数
的高维数特征空间中，以产生高维数特征空间内的第三向量集，该第
25 二维数具有比第一维数高的维数；产生用于第三向量的 Kernel
Fisherfaces；根据第三向量和 Kernel Fisherfaces 来在第三维数面部图像
空间中产生第四向量集，该第四向量对应于面部图像空间内的参考面
部图像点，并且第三维数具有比第一维数和第二维数低的维数；使用
投射函数 $\Phi(x)$ 来投射第二向量到高维数特征空间，以产生高维数特
30 征空间内的第五向量；根据第五向量和 Kernel Fisherfaces 来在面部图

像空间内产生第六向量，该第六向量对应于面部图像空间内的输入面部图像点；计算面部图像空间内输入面部图像点和每个参考面部图像点之间的距离；以及，响应于确定所计算距离的最小值，来将输入面部图像识别为对应于与该最小距离相对应的参考面部图像。

5

根据本发明的另一方面，提供了一种面部识别系统，用于将输入面部图像识别为对应于参考面部图像集内特定面部图像的方法，参考面部图像由第一向量集表示，且输入面部图像由在第一维数的输入空间内的至少第二向量表示，该面部识别系统包括：高维数特征空间投射模块，其用于使用投射函数 $\Phi(x)$ 来投射第一向量和第二向量到第二维数的高维数特征空间中，以分别产生第三向量和第四向量，该第二维数具有比第一维数高的维数；Kernel Fisherfaces 模块，其用于计算第三向量的 Kernel Fisherfaces；面部图像投射模块，其用于使用 Kernel Fisherfaces 来在第三维数的面部图像空间中从第三向量产生第五向量集，和从第四向量中产生第六向量，该第五向量对应于面部图像空间内的参考面部图像点，且该第六向量对应于面部图像空间内的输入面部图像点，并且该第三维数具有比第一维数和第二维数低的维数；以及，距离计算模块，其用于计算面部图像空间内输入面部图像点和每个参考面部图像点之间的距离。

10
15
20

附图说明

通过考虑下面的结合附随附图的详细说明，将更容易理解本发明的教导。在附随附图中相同参考标记用于相同元件。

25 图 1A 是显示根据本发明一个实施例，面部识别系统使用参考面部图像集练习的图。

图 1B 是显示根据本发明一个实施例，在参考面部图像集中识别特定输入面部的图。

30 图 1C 是显示根据本发明一个实施例的在图 1A 和 1B 中所显示的面部识别系统 104 结构的框图。

图 1D 是显示根据本发明一个实施例,如何将面部图像表示为向量矩阵和如何在面部识别系统 104 中修正那些向量的图。

图 2 是显示根据本发明一个实施例,用参考面部图像集来训练面部识别系统的方法的流程图。

5 图 3 是显示根据本发明一个实施例,从参考面部图像集中识别特定面部图像的方法的流程图。

图 4 是显示根据本发明一个实施例,在第一测试面部图像集中测试面部识别系统的结果的图表。

10 图 5 是显示根据本发明一个实施例,在第二测试面部图像集中测试面部识别系统的结果的图表。

具体实施方式

图 1A 是显示根据本发明一个实施例,面部识别系统使用参考面部图像集的面部识别系统练习的图。参考图 1A,输入参考面部图像集 102 到面部识别系统 104 中。参考面部图像 102 是稍后将和输入面部图像进行比较以识别面部的面部图像。面部识别系统 104 分析并以下面将详细说明的方式用参考面部图像 102 的图像数据来进行练习,从而稍后面部识别系统 104 可以确定输入面部图像和参考面部图像 102 之一相像。

20

图 1B 是显示根据本发明一个实施例,面部识别系统将输入面部图像识别为和参考面部图像集中的某特定面部图像相像的图。已经用图 1 所示的参考面部图像集来训练了面部识别系统 104。参考图 1B,输入面部图像 106 被面部识别系统 104 接收。面部识别系统 104 确定输入面部图像 106 是否和参考面部图像集 102 内的面部图像之一相像,还确定它和哪个特定面部图像相像。从面部识别系统 104 输出此结果 108。

25

图 1C 是显示根据本发明一个实施例,在图 1A 和 1B 中显示的面部识别系统 104 结构的图。参考图 1C,面部识别系统 104 包括:高维数投射模块 110, Kernel Fisherface 计算模块 112,面部图像空间投射模

30

块 114, 距离计算模块 118, 以及存储模块 120。高维数投射模块 110 从输入空间投射面部图像 (图像集 102 或输入面部图像 106) 到高维数特征空间, 从而从所投射的参考面部图像 102 或输入面部图像 106 的高阶统计获得更多表示特征。该高维数特征空间比输入空间具有更多维数。投射面部图像到该高维数特征空间是通过使用投射函数执行在表示面部图像的向量之间的多种各种运算来实现的。Kernel Fisherface 模块 112 计算在该高维数特征空间内的投射参考面部图像 102 的特征值和特征向量 (Kernel Fisherface)。面部图像空间投射模块 118 通过使用所计算的 Kernel Fisherface 从高维数特征空间投射面部图像到较低维数面部图像空间, 来获得参考面部图像 102 或输入面部图像 106 的面部图像空间表示。面部图像空间的维数通常低于输入空间和用于多数面部识别图像采样的高维数特征空间。

存储模块 120 存储参考面部图像 102 的表示到较低维数面部图像空间中, 以用于和输入面部图像 106 进行比较。存储模块 120 还存储计算的 Kernel Fisherface, 以和输入面部图像一起使用。距离计算模块 118 计算面部图像空间内对应于输入面部图像 106 的点和面部图像空间内对应于参考面部图像 102 的每个点之间的距离, 并确定哪个距离最短, 从而识别哪一个特定参考面部图像 102 和输入面部图像 106 是相像的。根据本发明一个实施例, 所计算距离是欧几里得距离。然而, 其他类型的距离也可以和本发明一起使用。和面部识别系统 104 内的各种模块相关的数学和算法的细节将在下面详细说明。

图 1D 是显示根据本发明一个实施例, 如何用向量矩阵来表示面部图像和如何在面部识别系统 104 中修正这些向量的图。首先, 各面部图像 (参考面部图像或输入面部图像) 用向量表示, 面部图像集 122 在输入空间中用向量矩阵 124 表示。通常, 面部图像是二维 $N \times N$ 强度值阵列。让 $n = N^2$ 。每个面部图像在输入空间中都表示为矩阵 124 中的向量 $A_1, A_2, A_3, \dots, A_m$ 之一, 每个都有维数 n , 其中 m 等于用矩阵向量所表示的面部图像的数目, 且 n 等于 N^2 。换句话说, 矩阵 124

有 m 行 n 列。例如，假定在面部识别系统中使用了 40 个对象 (subject) 的 400 幅图像，且图像的分辨率是 23×23 。则， m 等于 400，且 n 等于 529 (23×23)。

5 本发明的面部识别系统 104 投射输入空间内的向量矩阵 124 到高维数特征空间，以从图像内像素间的高阶统计中提取面部图像的更多表示特征，使得在高维数特征空间产生向量 $B_1, B_2, B_3, \dots, B_m$ 的矩阵 126。向量 $B_1, B_2, B_3, \dots, B_m$ 是根据投射函数在向量 $A_1, A_2, A_3, \dots, A_m$ 中各种运算而产生的结果，并具有比向量 $A_1, A_2, A_3, \dots, A_m$ 更高的维数。换句话说，矩阵 126 具有 m 行和 f 列，其中 f 比 n (即矩阵 124 中的列数目) 大得多。列 f 的数目取决于所选择的投射函数。

15 然后，面部识别系统 104 投射向量矩阵 126 到低维数面部图像空间，该低维数面部图像空间的维数低于高维数特征空间且通常其维数也低于输入空间，这导致产生在低维数图像空间内的向量 $C_1, C_2, C_3, \dots, C_m$ 的矩阵 128。通过使用 Kernel Fisherfaces，简化了此处理中所包含的计算，如下面将要详细说明的。向量 $C_1, C_2, C_3, \dots, C_m$ 通常具有低于向量 $A_1, A_2, A_3, \dots, A_m$ 和向量 $B_1, B_2, B_3, \dots, B_p$ 维数的维数。换句话说，矩阵 128 有 m 行和 d 列，其中 d 比 n 和 f 小得多 (即分别是矩阵 124 和 126 内列的数目)，并通常具有等于面部图像内对象数目减 1 的值。在以上例子中， d 等于 39 ($40-1$)。

25 图 2 是显示根据本发明一个实施例，用参考面部图像集来训练面部识别系统 104 的方法的流程图。参考图 2，在 202 获得参考面部图像集。开始，参考面部图像由用于每个像素的强度值矩阵组成。为此目的，使用各种面部表情和在各种照明条件下为每个人收集参考面部图像。换句话说，用照明和表情变化来对每个人收集图像集。然后，执行常规图像处理，以排列每个参考面部图像内的例如眼睛和鼻子的元素，且每个参考面部图像都用分类标识来进行标记。即，每个面部图像集都用识别符来标记 (例如一个数字)，它反映该人图像的标识特性。

30

例如，为 John 收集一个 15 幅面部图像集，且每个面部图像都用分类数字 1 标记。类似的，为 Jane 收集一个 15 幅面部图像集，且每个面部图像都用分类数字 2 标记等。这些面部图像用作用于面部识别的参考图像。然后，每个参考面部图像用向量形式的强度值的光栅扫描来表示，
5 且参考面部图像集可用包括多个向量的矩阵形式表示。例如，按行来断开 100x100 像素面部图像中的 10,000 像素中的每一个，且每个像素（范围从 0 到 255）的强度值都以 1x10,000 向量的形式输入。产生的矩阵是 $m \times 10000$ 矩阵的形式，其中 m 是参考面部图像数目。在 Turk 等人的美国专利 Re.36,041 中详细公开了获得以输入向量形式的面部图
10 像的方法。

随后，在 204，由高维数投射模块 110 来投射参考面部图像 102 到维数比输入空间高的高维数特征空间，从而获得图像的更多表示特征。可从图像内的高阶统计相关性（例如三个或多个像素之间的关系）
15 来得到这些更多表示特征。如上所述，这种图像内的高阶相关性可以包括像素强度值之间的关系，例如在边缘或曲线内的三个或多个像素之间的关系。

和例如那些在 Turk 等人的美国专利 Re.36,041 中所公开的常规面部识别系统相反，在这样的系统中不使用图像内的高阶相关性，而是用协方差矩阵来编码面部图像之间的关系。常规面部识别系统中的协方差矩阵是根据二阶统计的，即，像素值（考虑每两个像素）两两相乘，而投射模块 204 允许多于两个像素值相乘，从而计算像素（多于
20 两个像素）间的高阶统计。这样的高阶统计通常捕获了边缘内或曲线上三个或多个像素间的内在关系。高阶相关性通常具有图像的更多有意义的表示特征，并和二阶统计比较，捕获用于面部识别的重要信息。这是因为二阶统计对应于图像的振幅谱，而高阶统计对应于相位谱。相位谱捕获了结构信息，并提供有意义的面部图像表示。

30 可根据投射函数通过在表示参考面部图像的向量之间执行各种类

型的运算来实现参考面部图像 102 到高维数特征空间的投射。例如，可以使用以下投射函数来投射二维空间中的向量到三维特征空间中：

$$\Phi: R^2 \rightarrow R^3$$

$$(x_1, x_2) \rightarrow (x_1^2, x_2^2, \sqrt{2} x_1 x_2)$$

5

类似的，可以使用下面的投射函数来投射二维空间中的向量到四维特征空间：

$$\Phi: R^2 \rightarrow R^4$$

$$(x_1, x_2) \rightarrow (x_1^2, x_2^2, x_1 x_2, x_2 x_1)$$

10

也可能使用其他各种投射函数来投射 n 维面部图像到 f 维特征空间（ f 比 n 大得多）。特定投射函数的选择取决于数据和应用，并通常根据经验确定。

15

本发明可使用多种形式的投射函数 $\Phi(x)$ 。然而，仅有有限数目的投射函数是和有效、系统化计算相兼容。选择特定投射函数 $\Phi(x)$ 的一种方法是选择以下这种投射函数：可使用 kernel 函数有效计算其点积，而不是通过实际执行投射函数的点积运算来计算，因为投射函数的点积运算通常用在从高维数特征空间投射面部图像到低维数面部图像空间所实施的计算和计算强度中。因此，此种方法得出满足下列关系的 kernel 函数 $k(x, y)$ ：

$$k(x, y) = \Phi(x) \cdot \Phi(y)$$

20

通常，和使用点积 $\Phi(x) \cdot \Phi(y)$ 的计算相比，使用 kernel 函数 $k(x, y)$ 的计算可更有效地实施，因为使用 kernel 函数 $k(x, y)$ 的计算取决于 n 维输入空间（通常是低的），而 $\Phi(x) \cdot \Phi(y)$ 的计算取决于 $\Phi(x)$ 和 $\Phi(y)$ 的维数，通常该维数非常高，可以是无限大。

25

本领域公知 Mercer 条件（还通常作为 Mercer 定理公知）作为确定是否某个 kernel 函数 $k(x, y)$ 可用于计算输入空间内而非高维数特征空

间内的投射采样的点积 ($\Phi(x) \cdot \Phi(y)$) 的方法。然而, 可根据任何其他方法或定理 (甚至是经验的) 选择投射函数。对于本领域技术人员来说, Mercer 定理是已知的, 并在 Data Mining and Knowledge Discovery (数据挖掘 (mining) 和知识发现) 1998 年第 2 卷第 2 期第 121-167 页 Christopher J.C.Burges 的 “A Tutorial on Support Vector Machines for Pattern Recognition” 中详细说明。

大约有 24 种 kernel 函数满足 Mercer 条件。多项式 kernel ($k(x,y)=(x \cdot y)^d$) 以及高斯 kernel (其中 $\sigma^2 k(x,y) = e^{-\|x-y\|^2/2\sigma^2}$ 是高斯分布的标准偏差, x 、 y 来自该高斯分布) 是最广泛使用的 kernel 函数。根据本发明一个实施例, 二次 ($d=2$) 多项式 kernel 被用作投射函数。根据本发明的另一个实施例, 三次 ($d=3$) 多项式 kernel 被用作投射函数。注 $\left[\begin{smallmatrix} d \\ d \end{smallmatrix} + n - 1 \right]$ 意到投射函数 ($\Phi(x)$, $\Phi(y)$) 的确切形式完全由选定的 kernel 函数 $k(x,y)$ 所规定。实际上, 无需知道投射函数的确切封闭形式, 只要在从高维数特征空间投射面部图像到较低维数面部图像空间的计算中使用投射采样的点积 $\Phi(x) \cdot \Phi(y)$, 因为另外 kernel 函数 $k(x,y)$ 可以按照高效计算方式被用于执行这样的投射。因此, 使用 kernel 函数的一个优点是, n 维面部图像可被投射到 f 维特征空间 (f 比 n 大得多), 该空间提供了更丰富的特征表示, 而不用知道投射函数的确切封闭形式。当使用 d 次多项式 kernel 函数时, 高维数特征空间的维数 f 是 例如, 对于 $d=2$ 次的多项式 kernel 和包括 16 乘以 16 像素 ($n=256$) 的面部图像, 高维数特征空间的维数 f 是 32,896 (比输入空间维数大 128 倍)。

使用此种投射函数从输入空间投射面部图像到高维数特征空间的原因是多样的。首先, 投射到较高维数特征空间的面部图像比起在原始输入空间内的面部图像提供了更有表现力的特征表示。投射函数计算各种统计信息以表现图形, 这非常重要, 因为更有表现力的特征表示通常辅助于图形分类任务。第二, 投射函数允许图形内特征之间的非线性表示。例如, 上述投射函数的例子说明图形内特征之间的关系。

第三，投射函数允许在较高维数空间内执行分类任务，这使得分类任务更容易。换句话说，在输入空间中不是线性可分的图形在高维数特征空间内通常是线性可分的。

5 再次参考图 2，在 206，Kernel Fisherface 计算模块 112 从高维数特征空间内所投射的参考面部图像中计算 Kernel Fisherfaces。在计算 Kernel Fisherfaces 中所包含的技术将在下面详细说明。

10 在 208，通过面部图像空间投射模块 114 使用所计算的 Kernel Fisherfaces 来从高维数特征空间投射参考面部图像到低维数面部图像空间，使在低维数面部图像空间内产生对应向量。在整体结构上类似的面部图像不是随机分布在高维数特征空间内的，且因此可由相对较低维数的子空间来进行描述。Kernel Fisherfaces 可以简化从高维数特征空间内所投射的参考图像中导出在低维数面部图像空间内的面部图像描述所包含的计算。较低维数面部图像空间的维数通常低于输入空间和高维数特征空间的维数，其中输入面部图像被投射到该高维数特征空间。

20 随后，在 210，在存储模块 120 中存储 Kernel Fisherfaces 和对应于低维数面部图像空间内参考面部图像的向量分布，以将来用于和输入面部图像进行比较。因此，存储模块 120 将具有面部图像空间内的向量分布，该面部图像空间对应于参考面部图像集，稍后输入面部图像将和该参考面部图像集比较，以进行面部识别。

25 图 3 是显示根据本发明一个实施例，识别在参考面部图像集中的特定面部图像的方法的流程图。首先，在 302，获得输入面部图像 106，以和先前存储的参考面部图像 102 比较。在 302，以和以上所述的获得参考面部图像 102 相同的方式获得向量形式的输入面部图像 106。如果仅有一个输入面部图像，则输入空间中的向量矩阵 124 是单向量矩阵
30 (1xn 矩阵)。高维数投射模块 110 投射输入面部图像 106 到高维数特

征空间，以获得输入面部图像 106 的更多表示特征。随后，在 308，先前在 206 计算的关于参考面部图像的 Kernel Fisherfaces 被面部图像空间投射模块 114 用于投射输入面部图像到面部图像空间。

5 此时，在所投射的较低维数面部图像空间中存在对应于输入面部图像 106 和参考面部图像集 102 的点（对应向量）。对应于参考面部图像 102 的点（向量）被存储到存储模块 120 中，但可由距离计算模块 118 检索。在 310，距离计算模块 118 计算在输入面部图像点和对应于较低维数面部图像空间内参考面部图像 106 的每一点之间的欧几里得距离。距离计算单元 118 确定最短计算距离。和对应于该最短距离的点相关联的参考面部图像是参考面部图像中最相像于输入面部图像的特定面部图像，且分配给此特定面部图像的分类标识是面部识别的结果。

15 现在将详细说明在每个上述步骤之下的数学方法。

特征值问题

通常，面部识别是二维强度值 N 乘 N 阵列。在多维图像空间中面部图像表示为 N^2 维数的向量。例如，256 乘 256 像素大小的典型图像成为 65,536 维数的向量，或等同于 65,536 维图像空间内的一个点。类似的，面部图像集映射到该 65,536 维图像空间的点集上。如上所述，本发明的面部识别系统投射图像（输入面部图像或参考面部图像）到高维数特征空间，以从图像内像素间的高阶统计中提取图像的更多表示特征。由于面部图像在整体结构上类似，因此，它们不是随机分布在图像空间内的，并可由低维数子空间来描述。此外，属于同一个人的面部图像集通常在低维数子空间内形成较小的群。换句话说，同一个人面部图像的个人内（分类内）变化比个人间（分类间）变化小。使用 Kernel Fisher 线性判别式（KFLD）分析，有可能识别最佳分离低维数面部图像空间内的群的投射向量。这些投射向量被称为 Kernel Fisherfaces，且计算这些 Kernel Fisherfaces 的过程等同于解决高维数特

征空间内图像的基本特征值问题。然而，kernel 函数（并因此 Kernel Fisherface）的使用为解决特征值问题提供了高效计算方法。

假定居中的 m 集（零平均值，单位变化）采样 $x_k, x_k=[x_{k1}, x_{k2}, \dots, x_{kn}]^T \in R^n$ (R^n 是输入空间)，FLD 得出在所投射低维数面部图像空间内最大化群之间变化同时最小化每个群内变化的投射方向。换句话说，FLD 的目标是得出投射方向，从而采样分类的采样被投射，以在低维数面部图像空间内（即，最小化分类内散布 S_W 或每个群内的变化）形成压缩群，同时尽可能分离群（即，最大化分类间散布 S_W 或各群间的变化）。因此，应当得出最大化下面标准函数 $J(w)$ 的向量 w ：

$$J(w) = \frac{|S_B|}{|S_W|} = \frac{|w^T S_B w|}{|w^T S_W w|} \quad (1)$$

最大化 $J(w)$ 的最佳解决方案是对特征值问题的解决方案。最佳 w 的列是对应于最大特征值的广义特征向量：

$$S_B w = \lambda S_W w \quad (2)$$

对于特征值 $\lambda \geq 0$ 以及特征向量 $w \in R^n$ (R 是实数)。输入空间 R^n 内的分类内散布矩阵 S_W 由

$$S_W = \sum_{i=1}^c S_i \quad (3)$$

$$S_i = \sum_{x \in X_i} (x - \mu_i)(x - \mu_i)^T \quad (4)$$

$$\mu_i = \frac{1}{n_i} \sum_{x \in X_i} x \quad (5)$$

规定，其中 c 是分类总数， μ_i 是分类平均值， n_i 是分类 i 中的采样数，且 $x \in X_i$ 。类似的，在输入空间 R^n 中的分类间散布矩阵 S_B 由

$$S_B = \sum_{i=1}^c n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (6)$$

规定，其中 c 是分类数， μ_i 是分类平均值，且 n_i 是分类中的采样数， μ 是在所有分类中的向量 x 的总平均值，不管该向量属于哪个分类，

$$\mu = \frac{1}{n} \sum_x x$$

即 (n 是所有分类中的采样 (或向量) 数目, 且 x 是任意分类中的向量, 不管它属于哪个分类)。

投射图像到高维数特征空间

5 在 Kernel FLD 分析中, 从输入空间 R^n 通过非线性映射函数 (投射函数) 来投射每个向量 x 到高维数特征空间 R^f 中的 $\Phi(x)$:

$$\Phi: R^n \rightarrow R^f \quad f > n \quad (7)$$

上面说明了投射函数 Φ 的例子。高维数特征空间的维数 f 可为任意大。分别用 $1\mathfrak{S}_w^\Phi$ 和 $1\mathfrak{S}_B^\Phi$ 表示在高维数空间 R^f 内的分类内和分类间的散布矩阵, 并在高维数 Kernel 空间 R^f 内应用 FLD, 必需得出到特征值问题的特征值 λ 和特征向量 w^Φ :

$$15 \quad S_B^\Phi w^\Phi = \lambda S_w^\Phi w^\Phi \quad (8)$$

在高维数空间 R^f 内使用等式 (2)、(3)、(4) 和 (5), 以下等式遵循

$$S_w^\Phi = \sum_{i=1}^c S_i^\Phi \quad (9)$$

$$20 \quad S_i^\Phi = \sum_{x \in X_i} (\Phi(x) - \mu_i^\Phi)(\Phi(x) - \mu_i^\Phi)^T \quad (10)$$

$$\mu_i^\Phi = \frac{1}{n_i} \sum_{x \in X_i} \Phi(x) \quad (11)$$

$$S_B^\Phi = \sum_{i=1}^c n_i (\mu_i^\Phi - \mu^\Phi)(\mu_i^\Phi - \mu^\Phi)^T \quad (12)$$

$$25 \quad \text{其中 } \mu^\Phi \text{ 是向量 } \Phi(x) \text{ 的总平均值, 即 } \mu^\Phi = \frac{1}{n} \sum_x \Phi(x)$$

下面是在高维数空间 R^f 内的最佳投射矩阵 W_{OPT}^Φ 是:

$$w_{OPT}^\Phi = \operatorname{argmax}_{w^\Phi} \frac{|(w^\Phi)^T S_B^\Phi w^\Phi|}{|(w^\Phi)^T S_w^\Phi w^\Phi|} = [w_1^\Phi, \dots, w_m^\Phi] \quad (13)$$

其中是 $\{w_i^\Phi | i = 1, 2, \dots, m\}$ 对应于 m 最大广义特征值 $\{\lambda_i | i = 1, 2, \dots, m\}$ 的广义特征向量集。等式 (13) 中的 “ $\operatorname{argmax}_{w^\Phi}$ ” 得出

最大化根据 $\arg \max$ 的比率的 w° 。

5 为避免计算 w° 中的奇点问题，根据本发明一个实施例，将小单位矩阵 I 加到 S_w° ，从而使其数字稳定。换句话说， $S_w^\circ = S_w^\circ + \epsilon I$ ，其中 I 是其维数和 S_w° 相同的单位矩阵， ϵ 是小实数，例如根据本发明一个实施例是 0.001。通过将小实数加到分类内散布矩阵的对角线，分类内散布矩阵的对角线上的元素不会为零，从而消除奇点问题。

计算 Kernel Fisherfaces

10 考虑 c -分类问题（即每个采样属于 c 分类中的一个），并让分类 t 的第 r 个采样和分类 u 的第 s 个采样分别是 x_{tr} 和 x_{us} （其中分类 t 有 l_t 个采样，且分类 u 有 l_u 个采样）。kernel 函数定义为

$$(k_{rs})_{tu} = k(x_{tr}, x_{us}) = \Phi(x_{tr}) \bullet \Phi(x_{us}) \quad (14)$$

15 让 K 是由元素 $(K_{tu})_{u=1,\dots,c}^{t=1,\dots,c}$ 定义的 $m \times m$ 矩阵，其中 K_{tu} 是由高维数特征空间 R^f 内点积组成的矩阵。

$$K = (K_{tu})_{u=1,\dots,c}^{t=1,\dots,c} \quad (15)$$

其中

$$K_{tu} = (K_{rs})_{s=1,\dots,l_u}^{r=1,\dots,l_t} \quad (16)$$

20 在此， K_{tu} 是 $l_t \times l_u$ 矩阵， K 是 $m \times m$ 对称矩阵。同样，矩阵 Z 定义为：

$$Z = (Z_t)_{t=1,\dots,c} \quad (17)$$

其中 (Z_t) 是全部项都等于 $\frac{1}{l_t}$ 的 $l_t \times l_t$ 矩阵，即 Z 是 $m \times m$ 块对角线矩阵。

在等式 (12) 和 (9) 中的高维数特征空间 R^f 内的分类间和分类内散布矩阵分别变为：

$$30 \quad S_B^\circ = \sum_{i=1}^c l_i \mu_i^\circ (\mu_i^\circ)^T \quad (18)$$

$$S_w^\circ = \sum_{i=1}^c \sum_{j=1}^{l_i} \Phi(x_{ij}) \Phi(x_{ij})^T \quad (19)$$

其中 μ_i^Φ 是 R^f 内分类 i 的平均值, l_i 是属于分类 i 的采样数。从重新产生 kernels 的理论中, 任何解 $w^\Phi \in R^f$ 必须位于 R^f 内所有链采样范围内, 即,

$$w^\Phi = \sum_{p=1}^c \sum_{q=1}^{l_p} \alpha_{pq} \Phi(x_{pq}) \quad (20)$$

5

随后是通过解以下等式获得 (20) 的解:

$$\lambda KK\alpha = KZK\alpha \quad (21)$$

随后, 等式 (13) 可被写为:

$$w_{OPT}^\Phi = \arg \max_{w^\Phi} \frac{|(w^\Phi)^T S_B^\Phi w^\Phi|}{|(w^\Phi)^T S_w^\Phi w^\Phi|}$$

10

$$\begin{aligned} &= \arg \max_{w^\Phi} \frac{|\alpha KZK\alpha|}{|\alpha KK\alpha|} \\ &= [w_1^\Phi, \dots, w_m^\Phi] \end{aligned} \quad (22)$$

其中等式 (22) 中的 “ $\arg \max_{w^\Phi}$ ” 得出最大化根据 $\arg \max$ 的比率的 w^Φ 。在等式 (22) 中获得的提取特征向量被称 $w^\Phi = [w_1^\Phi, \dots, w_m^\Phi]$ 为 Kernel Fisherface。

投射面部图像到较低维数面部图像空间

25

现在可以将高维数特征空间 R^f 内的向量 $\Phi(x)$ 投射到较低维数面部图像空间, 该较低维数面部图像空间是通过使用 Kernel Fisherface (特征向量) w^Φ 而跨越的。当 x 是在高维数特征空间 R^f 内投射是 $\Phi(x)$ 的测试采样时, 到特征向量 w^Φ 的投射 $\Phi(x)$ 成为对应于 $\Phi(x)$ 的非线性 Fisher 线性判别式 (FLD):

$$w^\Phi \cdot \Phi(x) = \sum_{p=1}^c \sum_{q=1}^{l_p} \alpha_{pq} (\Phi(x_{pq}) \cdot \Phi(x)) = \sum_{p=1}^c \sum_{q=1}^{l_p} \alpha_{pq} k(x_{pq}, x) \quad (23)$$

30

以这种方式, 能使用 kernel 函数提取 Fisher 线性判别式, 而不实

际执行由投射采样到高维数特征空间 R^f 所产生的繁重计算。

图 4 是显示根据本发明一个实施例，在第一测试面部图像集上测试面部识别系统结果的图表。第一测试图像集是 40 个对象的 400 幅图像（每对象 10 幅），其包括面部轮廓以及姿势中的变化和比例。然而，保持照明条件不变。为减少计算复杂性，每个面部图像都垂直下采样为 23x28 像素。每个面部图像都用强度值的光栅扫描表示，然后被归一化为零平均值向量。面部图像峰度平均值和标准偏差分别是 2.08 和 0.14。峰度是非高斯分布的测量值，根据第 4 阶瞬间量计算，并由

$$\text{kurt}(x) = E[x^4] - 3(E[x^2])^2$$

来定义，其中 E 是期望值。

使用“排除一个在外”策略执行所有测试。即，分类某人图像，从 m 图像集中删除该图像，从而有 m-1 参考面部图像和一个输入面部图像。该图表显示根据本发明的使用 KFLD 的面部识别系统，该系统和基于例如 ICA（独立分量分析）、SVM（支持向量机器）、PCA、KPCA（Kernel 原理分量分析）、LLE（局部线性嵌入）、Isomap、FLD 等其他面部识别算法的面部识别系统的误差率相比，具有最低的误差率。

图 5 是显示根据本发明一个实施例的在第二测试面部图像集上测试面部识别系统结果的图表。第二测试面部图像集具有 11 个对象的 165 幅精密裁剪的图像，其包括内部面部结构，例如眉毛、眼睛、鼻子、嘴和下巴，但不包括面部轮廓。为了计算效率，每个图像垂直下采样为 29x41 像素，然后用归一化强度值居中向量表示。面部图像峰度平均值和标准偏差分别是 2.68 和 1.49。

如图 4 所示的一样，使用“排除一个在外”策略执行测试。图 5 的图表也显示根据本发明的使用 KFLD 的面部识别系统，该系统和基于例如 ICA、SVM、PCA、KPCA、LLE、Isomap、FLD 等其他面部识别算法的面部识别系统的误差率相比，具有最低的误差率。

虽然将本发明示出了用于面部识别的方法和系统，但是，本领域技术人员应当清楚，本发明的面部识别系统也可以嵌入记录在任何类型的计算机可读介质上的计算机程序产品中。本发明面部识别系统的使用不限于识别面部图像，还可用于识别其它具有广泛变化和大量元素的复杂图像。

结合一个可能的实施例详细说明了本发明。本领域技术人员应当理解，本发明可用其它实施例来实践。首先，组件的特定命名、术语大写、属性、数据结构、或任何其他程序设计或结构方面不是强制性的或重要的，且实现本发明或其特征的机制可以具有不同名称、格式或协议。此外，该系统可通过硬件和软件组合来实现，如所述的，或全部用硬件元素实现。同样，在此描述的在各种系统组件之间的特定功能分割仅仅是示范性的，并不是强制性的；由单个系统组件执行的功能可由多个组件代替执行，且由多个组件执行的功能也可由单个组件替代执行。

以上说明中的某些部分以算法和信息中运算符号表示方面给出了本发明的特征。这些算法说明和表示是由那些数据处理领域中的技术人员所使用的方式，以最有效传送他们工作的内容到本领域其他技术人员。虽然进行功能或逻辑说明了这些运算，但应当理解，这些运算可用计算机程序来实现。此外，有时也证明这种方法是便利的，将这些运算配置称为模块或编码装置，而不丧失一般性。

然而，头脑中应当清楚，所有这些和类似的术语和适当的物理数量相关，且仅仅是应用到这些数量的方便标记。除非特别指明，否则从以下讨论中可以清楚，应当理解，在整篇说明中，使用例如“处理”、或“计算”、或“算出”、或“确定”、或“显示”等术语的讨论指的是计算机系统或类似的电子计算装置的动作和处理，它们是操控和转换在计算机系统存储器或寄存器或其他这样的信息存储器中表示为物理

(电子)数量的传输或显示装置。

本发明的某些方面包括在此描述的算法形式的处理步骤和指令。
应当注意到,本发明的处理步骤和指令可包含在软件、固件或硬件中,
5 且当包含在软件中时,可被下载到驻留到不同平台上,并从由实时网
络操作系统所使用的不同平台来进行运算。

本发明还涉及用于执行在此所述运算的设备。该设备可以是为所
需目的而特别构造,或它可包括通用计算机,该计算机由存储在计算
10 机内的计算机程序来选择性地激活或重配置。这样的计算机程序可存
储在计算机可读存储介质中,例如但不限于,任何类型盘,包括:软
盘、光盘、CD-ROM、磁光盘、只读存储器(ROM)、随机存取存储器
(RAM)、EPROM、EEPROM、磁或光卡、专用集成电路(ASIC),或
适用于存储电子指令的任何类型的介质,且每个都联接到计算机系统
15 总线。此外,在说明书中提到的计算机可包括单个处理器,或是采用
为增强计算能力而设计的多个处理器的结构。

在此给出的算法和显示并不固有的和任何特定计算机或其他设备
相关。可以和根据在此教导,各种通用系统也可以结合程序来使用,
20 或可证明这样易于构造更加专用设备来执行所需的方法步骤。从下面
的说明中将出现多种该系统的所需结构。此外,本发明并不是参考任
何特定程序语言进行说明。应当理解,可使用多种程序语言来实现在
此描述的本发明的教导,并提供了对特定语言的任何参考来公开本发
明的实现和最佳模式。

最后,应当注意到,在说明书中所选择使用的语言主要是为清楚
和教导目的,并不是选择用于刻画或限定本发明主题。相应的,本发
明公开是示例性的,但不限制本发明发明范围,本发明发明范围在后
面的权利要求中提出。

30

图1A




图1B




图1C




图1D




图2





图3






图4




图5