



(12)发明专利申请

(10)申请公布号 CN 111295681 A

(43)申请公布日 2020.06.16

(21)申请号 201880071162.0

(74)专利代理机构 中国国际贸易促进委员会专利商标事务所 11038

(22)申请日 2018.09.18

代理人 邹丹

(30)优先权数据

15/799,115 2017.10.31 US

(51)Int.Cl.

G06Q 10/06(2006.01)

(85)PCT国际申请进入国家阶段日

G06Q 30/02(2006.01)

2020.04.30

(86)PCT国际申请的申请数据

PCT/US2018/051409 2018.09.18

(87)PCT国际申请的公布数据

W02019/089146 EN 2019.05.09

(71)申请人 甲骨文国际公司

地址 美国加利福尼亚

(72)发明人 雷明 C·波佩斯库


权利要求书2页 说明书9页 附图5页

(54)发明名称

使用加权混合机器学习模型进行需求预测

(57)摘要

实施例通过接收多个过去时间段的物品的历史销售数据来预测物品的需求,该历史销售数据包括限定一个或多个特征集的多个特征。实施例使用特征集作为一个或多个不同算法的输入,以生成多个不同模型。实施例训练每个不同模型。实施例使用每个经训练的模型针对过去时间段中的一些或全部中的每个时间段生成多个过去需求预测。实施例确定每个过去需求预测的均方根误差(“RMSE”),并且基于RMSE,确定每个经训练的模型的权重,并对每个权重进行归一化。实施例然后通过组合每个经训练的模型的加权值来针对每个未来时间段生成物品的最终需求预测。



1. 一种预测物品的需求的方法,所述方法包括:

接收多个过去时间段的物品的历史销售数据,所述历史销售数据包括限定一个或多个特征集的多个特征;

使用所述特征集作为一个或多个不同算法的输入,以生成多个不同模型;

利用相同的训练集来训练每个不同模型,以生成多个经训练的模型;

使用每个经训练的模型,针对过去时间段中的一些或全部中的每个过去时间段生成多个过去需求预测,并针对每个未来时间段生成多个未来需求预测;

确定每个过去需求预测的均方根误差 (RMSE);

基于RMSE,确定每个经训练的模型的权重并对每个权重进行归一化;以及

通过组合每一个经训练的模型的加权值来针对每个未来时间段生成物品的最终需求预测。
2. 如权利要求1所述的方法,其中训练不同的模型包括使用机器学习算法进行训练。
3. 如权利要求2所述的方法,其中所述机器学习算法包括线性回归、支持向量机或人工神经网络之一。
4. 如权利要求1所述的方法,其中根据RMSE ($R(i)$) 确定权重 ($W(i)$) 如下: ($W(i) = 1/R(i)$)。
5. 如权利要求4所述的方法,其中每个权重如下被归一化:
$$W'(i) = W(i) / \sum_{j=1}^m W(j)。$$
6. 如权利要求5所述的方法,其中在第(x) 周的最终需求预测 ($F'(x)$) 包括 $F'(x) = \sum (w'(i) * f(i, x))$ 。
7. 如权利要求1所述的方法,其中最终需求预测被传输到专门的库存管理系统和专门的制造系统。
8. 一种其上存储有指令的计算机可读介质,所述指令在由处理器执行时使所述处理器预测物品的需求,所述预测包括:

接收多个过去时间段的物品的历史销售数据,所述历史销售数据包括限定一个或多个特征集的多个特征;

使用所述特征集作为一个或多个不同算法的输入,以生成多个不同模型;

用相同的训练集训练每个不同模型,以生成多个经训练的模型;

使用每个经训练的模型,针对过去时间段中的一些或全部中的每个过去时间段生成多个过去需求预测,并针对每个未来时间段生成多个未来需求预测;

确定每个过去需求预测的均方根误差 (RMSE);

基于RMSE,确定每个经训练的模型的权重并对每个权重进行归一化;以及

通过组合每个经训练的模型的加权值来针对每个未来时间段生成物品的最终需求预测。
9. 如权利要求8所述的计算机可读介质,其中训练不同的模型包括使用机器学习算法进行训练。
10. 如权利要求9所述的计算机可读介质,其中所述机器学习算法包括线性回归、支持向量机或人工神经网络之一。

11. 如权利要求8所述的计算机可读介质,其中根据RMSE(R(i))确定权重(W(i))如下:
($W(i) = 1/R(i)$)。

12. 如权利要求11所述的计算机可读介质,其中每个权重如下被归一化:

$$W'(i) = W(i) / \sum_{j=1}^m W(j)。$$

13. 如权利要求12所述的计算机可读介质,其中在第(x)周的最终需求预测($F'(x)$)包括 $F'(x) = \text{sum}(w'(i) * f(i, x))$ 。

14. 如权利要求8所述的计算机可读介质,其中最终需求预测被传输到专门的库存管理系统和专门的制造系统。

15. 一种需求预测系统,包括:

耦合到存储设备的处理器,所述处理器实现需求预测模块,所述需求预测模块包括:

接收多个过去时间段的物品的历史销售数据,所述历史销售数据包括限定一个或多个特征集的多个特征;

使用所述特征集作为一个或多个不同算法的输入,以生成多个不同模型;

利用相同的训练集来训练每个不同模型,以生成多个经训练的模型;

使用每个经训练的模型,针对过去时间段中的一些或全部中的每个过去时间段生成多个过去需求预测,并针对每个未来时间段生成多个未来需求预测;

确定每个过去需求预测的均方根误差(RMSE);

基于RMSE,确定每个经训练的模型的权重并对每个权重进行归一化;以及

通过组合每个经训练的模型的加权值来针对每个未来时间段生成物品的最终需求预测。

16. 如权利要求15所述的系统,其中训练不同的模型包括使用机器学习算法进行训练。

17. 如权利要求16所述的系统,其中所述机器学习算法包括线性回归、支持向量机或人工神经网络之一。

18. 如权利要求15所述的系统,其中根据RMSE(R(i))确定权重(W(i))如下:($W(i) = 1/R(i)$)。

19. 如权利要求18所述的系统,其中每个权重如下被归一化:

$$W'(i) = W(i) / \sum_{j=1}^m W(j)。$$

20. 如权利要求19所述的系统,其中在第(x)周的最终需求预测($F'(x)$)包括 $F'(x) = \text{sum}(w'(i) * f(i, x))$ 。

使用加权混合机器学习模型进行需求预测

技术领域

[0001] 一个实施例一般而言涉及计算机系统,并且特别地涉及预测需求的计算机系统。

背景技术

[0002] 产品通常通过制造商、分销商、运输商、零售商等的网络递送给消费者。一起向消费者递送产品的这种设施网络通常被称为“供应链”网络。

[0003] 产品的供应者(例如,制造商、供应商、零售商等)常常面临预测产品需求以便在存在不断变化的市场状况的情况下通过供应链网络提供平稳且高效的产品流的任务。过高估计需求可能导致生产过剩和与持有库存相关联的成本增加(例如,存储成本、过时(obsolescence)等)。另一方面,低估需求会导致收入损失。

[0004] 另外,在零售行业,零售商需要预估他们未来的需求,以更好地管理他们的库存或促销/降价计划。零售商可以参与许多类型的促销以提高他们的销售额。为了生成准确的预测,零售商必须考虑可能影响需求的所有因素,诸如促销、价格、季节性、天气等。

[0005] 用于预测产品需求的一种技术是主要基于该产品的历史需求信息(例如,基于过去的采购订单、过去的发货情况、过去的销售点数据等)来预测需求。但是,这种技术可能难以适应不断变化的市场状况,并且可能导致不准确的预测。另外,随着越来越多的因素需要考虑,传统的预测方法(诸如时间序列分析或回归)不能非常好地工作。

发明内容

[0006] 实施例通过接收多个过去时间段的物品的历史销售数据来预测物品的需求,该历史销售数据包括限定一个或多个特征集的多个特征。实施例使用特征集作为一个或多个不同算法的输入,以生成多个不同模型。实施例利用相同的训练集来训练每个不同模型,以生成多个经训练的模型。实施例使用每个经训练的模型针对过去时间段的一些或全部中的每个过去时间段生成多个过去需求预测,并针对每个未来时间段生成多个未来需求预测。实施例确定每个过去需求预测的均方根误差(“RMSE”),并且基于RMSE,确定每个经训练的模型的权重,并对每个权重进行归一化。实施例然后通过组合每个经训练的模型的加权值针对每个未来时间段生成物品的最终需求预测。

附图说明

[0007] 图1是根据本发明的实施例的计算机服务器/系统的框图。

[0008] 图2是根据一个实施例的在确定需求预测时图1的需求预测模块的功能的流程图。

[0009] 图3和图4图示了根据本发明的实施例的针对单个SKU的确定的需求预测的数值示例。

[0010] 图5图示了根据一个实施例的包括如本文所公开的需求预测的集成的制造、库存和物流系统。

具体实施方式

[0011] 一个实施例通过使用历史销售数据输入训练多个算法/方法和多个特征从而产生多个经训练的模型,并且然后基于误差值对每个经训练的模型进行加权来预测产品的需求。使用权重和多个模型,通过组合由每个经训练的模型生成的加权预测来生成需求预测。

[0012] 销售和预测方法大致可以被分为判断方法、外推方法和因果方法。外推方法仅使用活动本身的时间序列数据来生成预测。已知的特定算法/方法的范围从较简单的移动平均和指数平滑方法到更复杂的Box-Jenkins方法。虽然这些已知方法成功地识别和外推趋势、季节性和自相关的时间序列模式,但它们不考虑诸如价格改变和促销之类的外部因素。

[0013] 向量自回归(“VAR”)方法扩展Box-Jenkins方法以包括其它变量,但它们的复杂性使得估计很困难。因果预测涉及使用表示被认为是结果的驱动因素的现象的输入来构建定量模型。这些方法可以像具有促销变量的线性回归算法一样简单。起点是具有促销变量(诸如降价、折扣或广告)的回归模型。想法是模型的简单性帮助管理者理解以及批准或指导对模型的修改,并且随着他们对决策辅助知识的了解越来越多,他们可以准备好实现更精细和更复杂的模型。

[0014] 为了改进需求预测,零售商已经开始转向现代机器学习技术,诸如支持向量机(“SVM”)、神经网络(“ANN”)、随机森林等。但是,通常零售商将只会为每个产品/位置挑选一个模型。如本文所使用的,零售商可以包括单个零售商店,或者可以包括全部由单个或多个物流运作集成和管理的大量零售商店。

[0015] 另外,对于许多机器学习算法(SVM、ANN、随机森林等),零售商将使用特征集来定义产品/位置/日历交叉点处的数据点。在这些算法中,零售商将使用与用于预测的相同的特征集来训练模型。另外,相同的特征集可以被若干种不同的算法用于进行预测。“特征集”是影响物品需求的特征集合。特征的示例包括价格、季节性、品牌、促销、尺寸、颜色、包装尺寸、供应商、长度等。虽然诸如价格和季节性之类的特征可以对于所有类型的产品是相关的,但是一些其它特征是特定于物品的。例如,包装尺寸影响对酸奶的需求,但是长度是无关紧要的。相反,品牌对于时尚产品非常重要,但对于诸如钉子或锤子之类的五金产品则不那么重要。

[0016] 与针对每个产品/位置仅选择一个模型的用于需求预测的已知方法相比,实施例使用多个不同的经训练的模型一起来为零售商预估需求,然后使用新颖规则/算法来生成权重,该权重用于组合结果。

[0017] 图1是根据本发明实施例的计算机服务器/系统10的框图。虽然被示为单个系统,但是系统10的功能可以被实现为分布式系统。另外,本文公开的功能可以在可以经网络耦接在一起的单独的服务器或设备上实现。另外,可以不包括系统10的一个或多个组件。例如,对于服务器的功能,系统10可以需要包括处理器和存储器,但是可以不包括图1中所示的其它组件中的一个或多个,诸如键盘或显示器。

[0018] 系统10包括用于传送信息的总线12或其它通信机制,以及耦接到总线12用于处理信息的处理器22。处理器22可以是任何类型的通用或专用处理器。系统10还包括用于存储要由处理器22执行的信息和指令的存储器14。存储器14可以包括随机存取存储器(“RAM”)、只读存储器(“ROM”)、诸如磁盘或光盘之类的静态存储装置或任何其它类型的计算机可读

介质的任何组合。系统10还包括通信设备20,诸如网络接口卡,以提供对网络的访问。因此,用户可以直接地或通过网络远程地或以任何其它方法与系统10对接。

[0019] 计算机可读介质可以是可由处理器22访问的任何可用介质,并且包括易失性和非易失性介质、可移除和不可移除介质、以及通信介质。通信介质可以包括计算机可读指令、数据结构、程序模块或调制数据信号(诸如载波或其它传输机制)中的其它数据,并且包括任何信息递送介质。

[0020] 处理器22还经由总线12耦接到诸如液晶显示器(“LCD”)之类的显示器24。键盘26和诸如计算机鼠标之类的光标控制设备28还耦接到总线12,以使用户能够与系统10对接。

[0021] 在一个实施例中,存储器14存储当由处理器22执行时提供功能的软件模块。模块包括为系统10提供操作系统功能的操作系统15。模块还包括促销影响模块16,促销影响模块16确定需求预测,以及本文公开的所有其它功能。系统10可以是更大系统的一部分。因此,系统10可以包括一个或多个附加的功能模块18,以包括附加功能,诸如零售管理系统(例如,来自Oracle公司的“Oracle零售需求预测系统”或“Oracle零售高级科学引擎”(“ORASE”)或企业资源计划(“ERP”)系统。数据库17耦接到总线12,以便为模块16和18提供集中式存储并且存储客户数据、产品数据、交易数据等等。在一个实施例中,数据库17是可以使用结构化查询语言(“SQL”)来管理所存储的数据的关系数据库管理系统(“RDBMS”)。在一个实施例中,专用销售点(“POS”)终端100生成用于预测需求的交易数据和历史销售数据(例如,关于每个零售商店处的每个物品/SKU的交易的数据)。根据一个实施例,POS终端100本身可以包括用于预测需求的附加处理功能。

[0022] 在一个实施例中,特别是当存在大量零售商店、大量商品和大量历史数据时,数据库17被实现为存储器内数据库(“IMDB”)。IMDB是一种数据库管理系统,该数据库管理系统主要依赖于主存储器来存储计算机数据。它与采用盘存储机制的数据库管理系统形成对比。因为盘存取比存储器存取慢,所以主存储器数据库比盘优化的数据库更快,内部优化算法更简单,并且执行更少的CPU指令。存取存储器中的数据消除了查询数据时的查找时间,这提供比盘更快、更可预估的性能。

[0023] 在一个实施例中,当被实现为IMDB时,数据库17基于分布式数据网格来实现。分布式数据网格是其中计算机服务器的集合在一个或多个集群中一起工作以在分布式或集群环境内管理信息和相关操作(诸如计算)的系统。分布式数据网格可以被用于管理跨服务器共享的应用对象和数据。分布式数据网格提供低响应时间、高吞吐量、可预估的可扩展性、连续可用性和信息可靠性。在特定示例中,分布式数据网格(诸如,例如来自Oracle公司的“Oracle Coherence”数据网格)将信息存储在存储器内以实现更高的性能,并且采用冗余来保持该信息的副本跨多个服务器同步,从而确保系统的弹性以及在服务器发生故障时数据的持续可用性。

[0024] 在一个实施例中,系统10是计算/数据处理系统,该计算/数据处理系统包括用于企业组织的分布式应用的集合或应用,并且系统10还可以实现物流、制造和库存管理功能。应用和计算系统10可以被配置为与基于云的网络系统、软件即服务(“SaaS”)体系架构或其它类型的计算解决方案一起操作,或者被实现为基于云的网络系统、软件即服务(“SaaS”)体系架构或其它类型的计算解决方案。

[0025] 实施例使用从一个或多个不同算法生成的多个经训练的模型,以便估计销售预测

或需求预测。预测是供应链的重要驱动因素。如果预测不准确，那么分配和补货执行不佳，从而导致零售商的财务损失。通过本文公开的实施例可以实现对促销或非促销物品的预测准确性的改进。另外，可以更好地理解促销对需求的影响。例如，这有助于零售商更有效地计划有关渠道、定价和客户群的促销活动。

[0026] 从以下角度公开了实施例：对于在某个地点（例如，零售地点）销售的物品（例如，由SKU表示的零售物品），可以在各个时间（即，预定义的零售时段，诸如一天、一周、一个月、一年等）以各种方式促销物品。零售日历具有许多零售时段（例如，许多周），这些零售时段在典型的日历年中以特定方式（例如，四（4）个十三（13）周的季度）组织。零售时段可以在过去或未来发生。历史销售/业绩数据可以包括例如在多个过去零售时段的每一个中销售的物品的多个单位以及相关联的促销数据（即，对于每个零售时段，哪些促销对于该时段是有效的）。

[0027] 如下面所公开的，实施例使用根据一个或多个不同算法生成的一个或多个经训练的模型，并且为经训练的模型生成权重。在一些实施例中使用的经训练的模型可以包括经训练的线性回归模型或机器学习技术，诸如决策树或回归树、支持向量机（“SVM”）或神经网络。

[0028] 结合根据利用不同输入训练的线性回归算法生成的经训练的线性回归模型，对输出变量与多个输入变量之间的线性关系的搜索导致在回归设置中逐步选择输入变量。在一些实施例中，目标是构建将输出变量表达为输入变量的线性函数加上常数的函数。逐步回归中的两种一般方法是前向选择和后向选择。

[0029] 在前向选择中，根据预定的标准，基于变量对模型的贡献，一次一个地引入变量。在后向选择中，起初所有输入变量都被构建到模型中，然后如果基于预定标准判断输入变量对模型没有贡献，那么从回归公式中移除它们。

[0030] 在机器学习中，SVM是具有相关联的学习算法的受监督的学习模型，该学习算法分析用于分类和回归分析的数据。给定训练示例集，每个训练示例被标记为属于两个类别中的一个或另一个，SVM训练算法构建将新的示例指派给一个类别或另一个类别的模型，从而使它成为非概率的二元线性分类器。SVM模型是作为空间中的点的示例的表示，这些示例被映射为使得单独类别的示例被尽可能宽的明确间隙（gap）划分。然后将新的示例映射到同一个空间中，并基于它们落在间隙的哪一侧来预估该新的示例属于一个类别。

[0031] 除了分类之外，SVM还成功应用于销售或需求预测、能够处理常见的度量，诸如销售额，以及价格、促销、外部因素（诸如天气和人口统计信息）。

[0032] SVM及其支持向量回归（“SVR”）的回归版本使用内核函数隐式地将实例映射到更高维度的特征空间中。在它的最基本的形式中，SVR理想地寻求在这个空间中识别与被映射的输出点在一定距离内的线性函数。这种“软间隔（soft margin）公式”允许并惩罚超出预定距离的偏离，并最小化违反（violation）的总和以及识别线性关系的向量的范数。

[0033] 回归树技术以决策树格式将数据划分为较小的子集，并在用于预估结果的每个叶子处拟合线性回归模型。替代的模型树方法的彼此不同之处主要在于要被分支的输入变量的选择标准、所使用的拆分标准以及在树的每个叶子处构建的模型。虽然在针对特定情况的预估可以追溯到树中的条件和适用于满足那些条件的情况的回归函数的意义上树是透明的，但是具有许多层的树不容易以一般化的方式来解释。

[0034] 神经网络(“ANN”)是一种信息处理范式,其灵感来自生物神经系统(诸如大脑)处理信息的方式。这种模型的关键要素是信息处理系统的新颖结构。它由大量高度互连的处理元件(即,神经元)组成,这些处理元件协同工作以解决具体问题。ANN通过示例进行学习。通过学习过程为具体应用(诸如模式识别或数据分类)配置ANN。在生物系统中的学习涉及调整神经元之间存在的突触连接。对于ANN也是如此。由于神经网络最擅长识别数据的模式或趋势,因此它们非常适合预估或预测需求。

[0035] 图2是根据一个实施例的在确定需求预测时图1的需求预测模块16的功能的流程图。在一个实施例中,图2的流程图的功由存储在存储器或其它计算机可读或有形介质中的软件实现,并由处理器执行。在其它实施例中,功能可以由硬件(例如,通过使用专用集成电路(“ASIC”)、可编程门阵列(“PGA”)、现场可编程门阵列(“FPGA”)等)执行,或由硬件和软件的任意组合执行。

[0036] 在202处,针对特定类/类别的产品针对所有商店的所有物品接收历史物品销售数据。例如,类/类别可以是“酸奶”、“咖啡”或“牛奶”。每个类具有一个或多个子类,一直到SKU或通用产品代码(“UPC”)级别,这将是每个单独的待售物品,例如,对于酸奶类,子类可以是每个品牌的酸奶,并且进一步的子类可以是风味、尺寸、类型(例如,希腊或常规),直到与所售出的每种单独的不同类型的酸奶物品对应的SKU。每个SKU或UPC将被视为离散数据点或离散物品。

[0037] 历史销售和业绩数据可以包括例如表示跨多个过去零售时段的物品的过去销售和促销的数据。历史业绩数据可以被分段为过去几周的零售时段,其中过去的每周具有指派给它的数值以指示该周销售的物品的数量。根据一个实施例,历史业绩数据还可以包括表示跨零售时段的价格折扣和其它促销组成部分的值的数值。根据一个实施例,可以经由网络通信在中央地点访问物品的历史业绩数据,包括从每个零售商店的每个POS终端100访问和/或从数据库17访问物品的历史业绩数据。

[0038] 在图3和图4所示的一个示例实施例中,历史销售数据是针对单个SKU的,并且包括给定产品/地点(例如,多地点零售商的许多零售地点当中的单个零售地点)的过去的100周(即,第1-99周,其中第“99”周是历史数据的过去的最后一个最近的周,并且第“100”周是未来的第一周)的数据。这个示例实施例中的目标是预测在接下来/未来20周(即,第100-120周)在该位置对产品的需求。图3仅示出了过去的90-99周(在301处)(即,未示出第1-89周)。

[0039] 来自202的历史销售数据包括多个特征,从该多个特征中可以形成/限定多个特征集,并将其用作对一个或多个不同算法/方法的输入以生成多个不同模型。例如,一个特征集可以包括价格、品牌和颜色,并且第二特征集可以包括价格、季节性和供应商。

[0040] 在204处,由来自202的销售历史限定的特征集被用作生成一个或多个不同算法/方法的输入。在图3和图4所示的示例实施例中,使用了三种类型的算法:线性回归(行310)、SVM(行311)和ANN(行312)。代替不同类型的算法,可以使用使用不同特征集作为输入并因此出于实施例的目的而最终将生成不同的模型的单个类型的算法。例如,对于SVM,可以使用两种不同的模型,其中一个算法具有10个特征,并且一个模型具有20个特征。或者,对于ANN,一个模型可以包括1个隐藏层和10个节点,而一个模型可以包括2个隐藏层和5-7个节点。实施例限定特征集以描述可以用于训练/预估一组多个机器学习模型(“M”)中的每个模型的需求预测的数据点,其中该组模型包括“m”个模型。

[0041] 在206处,实施例使用相同的训练数据集训练该组模型M中的每个模型“i”。对于每个模型,实施例生成最终的经训练的模型T(i)。训练数据集可以包括影响需求的历史信息,诸如价格数据、销售数据以及所选择的特征的值。例如,如果物品是T恤,那么特征及其值可以是:品牌:Bo1o,颜色:粉红色,尺寸:中号,样式:V领,价格:\$15,销售量:13件。

[0042] 在208处,实施例使用来自206的经训练的模型针对预期的预测开始日期(在该例中的第100周)之前的“n”(在图3和图4的示例中为10)周生成需求预测。为了预估针对从日历索引k(例如,100)开始的L(例如,100)周的预测,不是使用该组模型来预估在第(k,k+1,...,k+L-1)周的需求时间序列,实施例预估在日历索引k-n(例如,100-10=90)处开始的额外n周。因此,预估的预测时间序列将为(k-n,k-n-1,...,k,k+1,...,k+L-1)。如图3所示,每个经训练的模型(即,线性回归(行310)、SVM(行311)和ANN(行312))用于生成第90-99周(这是存在历史销售数据的n周)的需求预测(即,不是未来需求预测)。

[0043] 在210处,使用来自206的每个经训练的模型来确定未来几周(即,第100-120周)的需求预测,如在列301和302处所示。一般而言,对于该组模型M中的每个模型,将经训练的模型T(i)应用于预估给定产品/地点从第k-n到第k+L-1周的预测F(i)。

[0044] 在212,针对从k-n到k-1的时段(即,预测时段之前的几周,或在图3和图4的示例中的第90-99周)确定每个预测F(i)的均方根误差(“RMSE”)R(i)。在一个示例中,通过在当前时间段(即,存在销售的最后一个时段)“n”周之前开始预测来确定RMSE。因此,对于这n周,既存在销售数据又存在可以生成的预测。利用销售数据和预测,可以使用已知的RMSE计算方法来计算RMSE。在图3和图4的示例中,从第90周到第99周使用三种经训练的模型或方法针对预测确定RMSE如下:

[0045]	RMSE (线性回归)	7.08
	RMSE (SVM)	7.96
	RMSE (ANN)	7.40

[0046] 在214处,基于在212处确定的RMSE为每个方法/经训练的模型“i”确定/分配权重如下:

[0047] $W(i) = 1/R(i)$ 。

[0048] 然后将每个权重如下归一化:

$$[0049] \quad W'(i) = W(i) / \sum_{j=1}^m W(j)$$

[0050] 它将所有权重加在一起,并对各个权重进行归一化,使得它们的总和等于1.0。例如,可能存在两个经训练的模型,其对应的RMSE分别为0.143和0.167。权重是RMSE的倒数,因此分别是7和6。归一化后的权重为:6/(6+7)=0.462和7/(6+7)=0.538。在图3和图4的示例中,所确定的权重如下:

[0051]	权重 (线性回归)	0.32
	权重 (SVM)	0.35
	权重 (ANN)	0.33

[0052] 在216处,通过组合先前确定的预测的每个经训练的模型的每个加权值来确定最终预测。实施例将在第“x”周的最终预测组合为 $F'(x) = \text{sum}(w'(i) * f(i, x))$,sum意为求和,

其中x表示从k到k+L-1的周索引,并且i表示经训练的模型。最终需求预测在图4中的行401示出。

[0053] 在218处,最终需求预测被用于制造生产、装运物流和库存控制。在一个实施例中,最终需求预测被发送到其它专用计算机,诸如库存控制系统、制造系统、装运和物流系统以及销售辅助系统。在一个实施例中最终需求预测是以单独的数据位的形式,这些单独的数据位已经从需求预测被转换并且被存储和发送到其它专用计算机系统,在那里它们由这些系统存储和使用。因此,附加物品可以被制造、存储、装运等,并且可以最佳地给物品定价。

[0054] 如所公开的,实施例的一个目标是为物品选择相关特征以最终最大化预测准确性。良好的预测一般不会带来任何借贷(credit)。物品总是可以获得并且它们以全价而不是折扣价出售。库存水平不应当太高,因此零售商的资金不会被库存占用。零售商和供应商应当能够可靠地计划劳动力和生产能力。

[0055] 但是,如果预测错误(即,不准确),那么情况会显著地变化。这些影响可能对许多业务领域产生负面影响。例如,如果预测太低,那么比所需的少的产品到达零售商并且销售一空。缺货情况给零售商带来收入损失并且客户满意度降低的影响。低的预测还会影响供应商,供应商必须缩减产量,并审查他们对当前劳动力的需求。

[0056] 如果预测过高,那么也存在负面影响。零售商将订购超过他们可以卖出的产品。如果产品易腐烂,那么它们可能会变质,从而增加浪费。即使它们不易腐烂,零售商也可能以折扣价出售额外的物品,这会对收入产生负面影响。否则,零售商可能将商品退还给供应商。这会影响供应商,因为他们拥有没有需求的额外的产品。另外,制造商可能浪费时间和金钱来生产错误的产品,这会对供应商的收入产生负面影响。

[0057] 图5图示了根据一个实施例的包括如本文所公开的需求预测的集成的制造、库存和物流系统500。如图5中所示,系统500可以包括产品预测系统570,该产品预测系统570预测未来的产品需求并且在一些情况下预测和/或考虑对数十万种产品的未来需求,或者在一些应用中预测在一个或多个零售商店501-504处的数千万或更多的产品。预测系统570通过云网络550或其它类型的通信网络与一个或多个库存系统520和一个或多个制造系统580进行通信。

[0058] 预测系统570通过实现结合上面的图2公开的功能来生成需求预测。库存系统520存储库存并提供运输物流以使用卡车510-513或一些其它运输机制将物品递送到商店501-504。在一个实施例中,库存系统520实现企业资源计划(“ERP”)专用计算机系统或专用库存控制系统,企业资源计划(“ERP”)专用计算机系统或专用库存控制系统使用来自预测系统510的输入来确定库存水平以及将物品递送到商店501-504的数量和时间。

[0059] 制造系统580制造要发送到库存系统520的物品,并提供运输物流以使用卡车581或一些其它运输机制将物品递送到库存系统520。在一个实施例中,制造系统580实现ERP专用计算机系统或专用制造系统,ERP专用计算机系统或专用制造系统使用来自预测系统570的输入来确定要制造的数量、用于制造的资源库存,以及将物品递送到库存系统520的数量和定时。

[0060] 预测系统570可以利用来自库存系统520、销售跟踪系统(未示出)和/或数据库的信息来预测对产品的需求。在预测需求时,预测系统570试图预估由事件、天气、社会需求、经济因素和其它因素导致的一种或多种产品的非典型需求。可以跟踪数十、数百到数千个

不同的变量,这些变量可以对一个或多个产品的需求产生影响。这些变量的变化可以导致非典型需求。例如,可以跟踪预测的天气的变化,并且可以使用与预测的天气相关联的一个或多个变量来确定这种天气变化是否可能对需求产生影响,并且是否可以进一步预测需求的变化。

[0061] 一般而言,图5的元素执行库存的销售、制造或消费。由于随机性和影响销售的外部因素,用于直接消费者销售的零售地点/商店501-504表现出最不稳定的库存模式。但是,消耗库存的制造设施和场所(诸如产品集成商、互联网装运商等在本地区域中使用的产品)也受益于本文所公开的需求预测。如所公开的,每个零售地点501-504将销售数据和历史预测数据发送到预测系统570。销售数据包括先前销售周期(即,几周)(通常是库存周期的4-7周)中每个销售时段(通常是几天)的每个物品或SKU/UPC的库存消耗统计信息。

[0062] 预测系统570将销售数据存储于在储存库572中,并采用销售数据来生成补充库存的订单。订单包括物品的集合和用于维持商店501-504的库存水平的每种物品的数量。

[0063] 许多零售订购计划依赖于销售时段和销售周期的一周中的天。在一种配置中,在具有库存统计信息的库存管理环境中,其中库存统计信息特定于一周中的每一天,库存系统520通过针对一周中的每一天搜集来自先前销售额的库存水平统计信息来确定目标库存水平。实施例基于库存水平统计信息来计算一周中的每一天的库存水平,使得安全存货适应一周中不同天之间的库存变化。对于多种物品中的每一种物品,实施例呈现指示目标库存水平的存货水平,包括一周中每天的安全存货。实施例基于订货交付时间计算订购数量,使得订购的数量达到关于一周中的所确定的一天的所呈现的存货水平。识别实际存货水平包括从历史数据中识别前几周的一周中的一天的存货水平,从而随着时间关注一周中的同一天,而不是一周中所有天的平均值。

[0064] 在特定配置中,所公开的实施例可以与专用和/或特别大批量的零售环境结合使用。在大型物流和配送操作中,尽可能装满卡车,并且如果需要将物品推迟到后续的行程,那么选择将最不可能中断销售活动的那些物品是有益的。因而,实施例可与POS系统100结合操作,以识别倾向于比其它物品更快地售出和补货的高周转率或高流通率物品。物品上的UPC条形码符号或射频标识(“RFID”)包括单独地或与数据库查找相结合将物品指定为适合如本文所定义的安全存货处理的高周转率物品的字段、标志或值。

[0065] 通过为库存数据库中表示的多个物品中的每一个识别产品标识符的字段和表示该物品的安全存货的字段,并基于指示由销售量导致的产品补货需求增加的产品周转率为每个产品标识符确定产品细分字段,可以提供高周转率物品。所公开的实施例基于周转率字段来确定是否计算安全存货,即,在给定产品吞吐量的情况下,根据安全存货进行重新供应的开销和负担是否值得。

[0066] 在其它实施例中,供应物流可以启用每天高于一卡车的递送频率,因此触发具有更高粒度的重新供应窗口。在这种情况下,安全存货可以比单独的一天更具体,诸如周一上午和周一下午,或者指定一周中的特定一天内的多个递送或时间窗口,诸如上午7:00、上午11:00和下午4:00。

[0067] 包括所生成的需求预测的实施例可以用于根据所运输物品的需求和利润率来实现供应物流并指定递送工具(即,卡车)和清单(即,包含的物品)。高周转率物品可能被视为在特定递送时具有优先级空间,但还可以基于所包括的物品的利润率或涨价而被选择,并

且选择包括具有最大创收潜力的物品。

[0068] 在使用本文公开的需求预测并且具有多个运输车辆的这种产品库存装运环境中，每个车辆(例如，卡车)被配置用于接收固定有效载荷的物品以便递送到销售地点以供库存补充。通过对于包括第一物品和第二物品在内的多个物品中的每种物品计算安全存货并基于计算出的第一物品和第二物品的安全存货来确定要装入递送车辆的第一物品和第二物品中的每种物品的量，实施例可以为装载递送车辆提供指导。如果在交付车辆中没有足够的空间用于第一物品和第二物品的确定的量，那么实施例基于安全存货重新计算卡车装载量，这意味着某些物品需要被省略并被推迟到后续的递送。

[0069] 如所公开的，实施例为未来销售时段确定一个或多个物品的需求预测。需求预测使用多个加权的不同的经训练的模型，这些模型已基于过去的销售数据进行了训练和加权。然后将生成的需求预测发送到其它专用系统，以控制预测物品的制造、库存控制、物流和其它功能。

[0070] 本文具体说明和/或描述了若干实施例。但是，应该认识到的是，在不脱离本发明的精神和预期范围的情况下，所公开的实施例的修改和变化由上述教导覆盖并且在所附权利要求要求的范围内。




图1

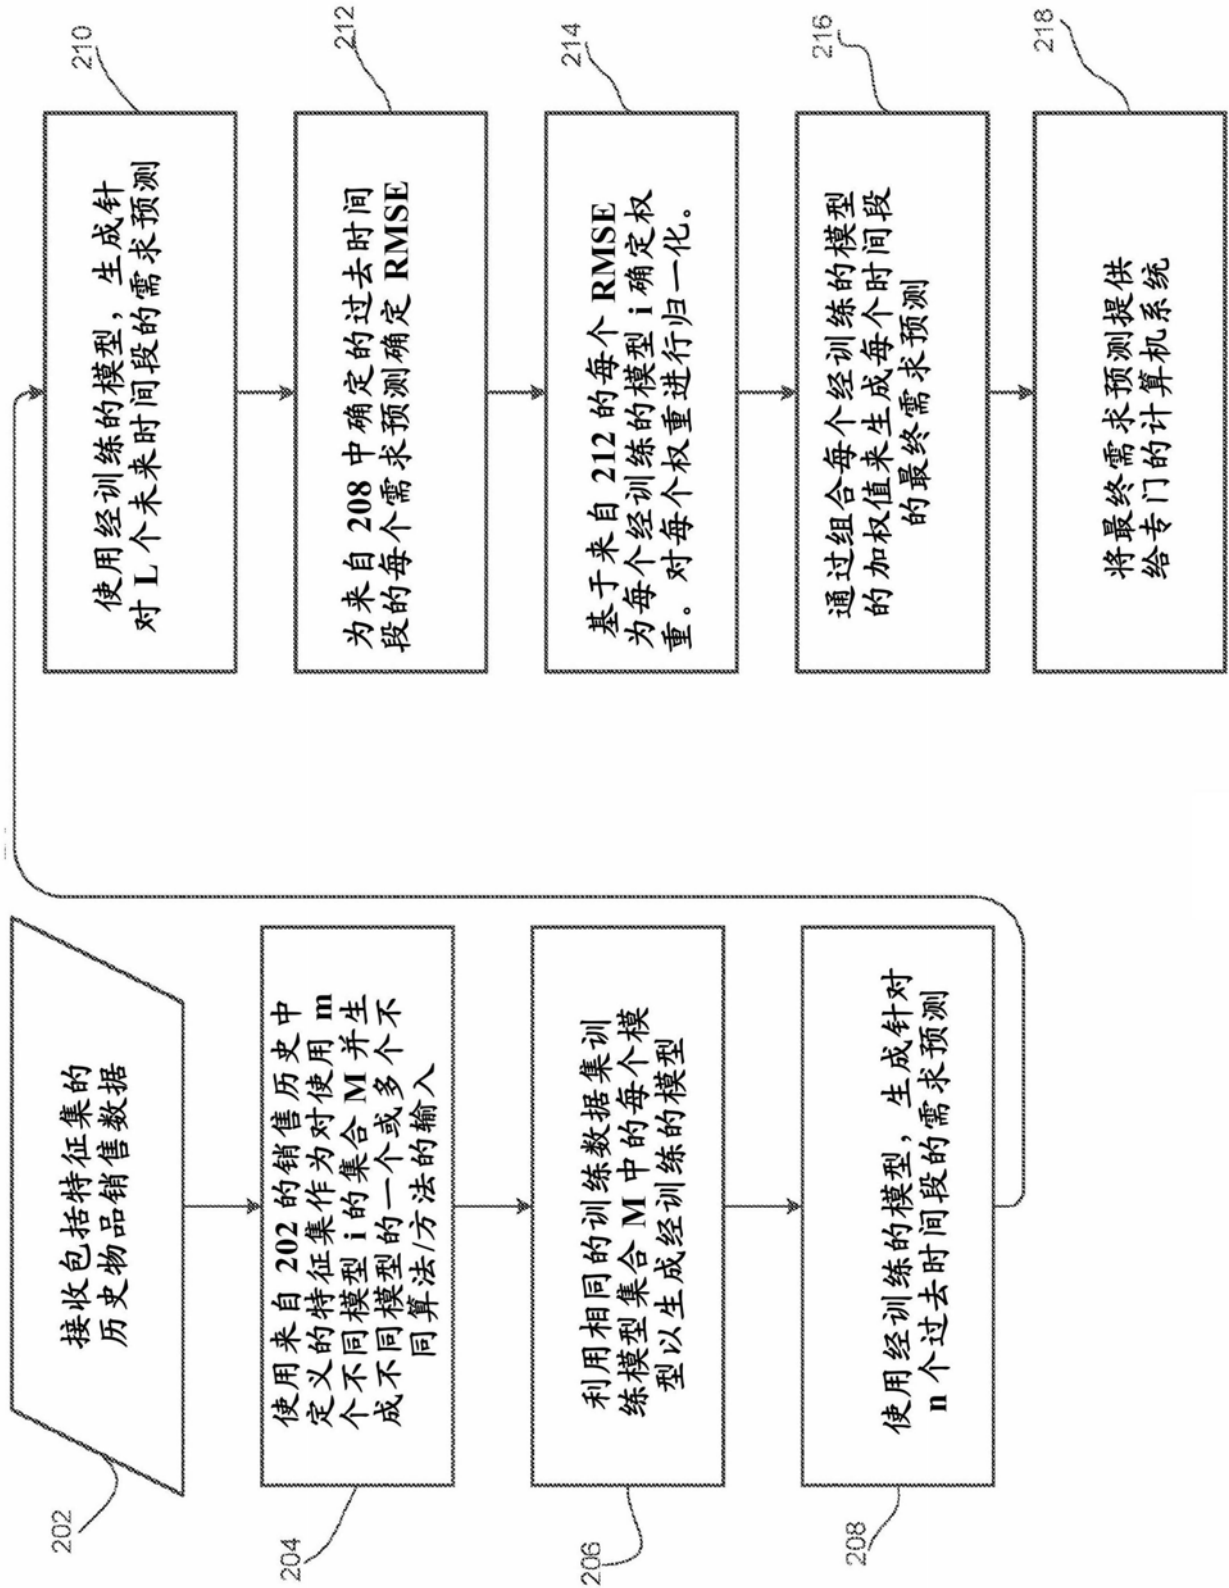


图2

周索引	100	101	102	103	104	105	106	107	108	109	110	111	112	113	114	115	116	117	118	119	120
预测 (线性回归)	26.40	21.80	28.80	28.20	24.90	15.60	16.80	18.40	26.70	23.70	12.00	24.30	28.10	29.40	22.60	18.70	28.10	13.30	22.20	27.00	15.50
预测 (SVM)	12.00	13.40	17.30	27.20	25.30	16.70	27.20	22.30	27.70	12.50	24.30	24.40	16.60	20.50	11.50	27.80	27.40	29.90	18.50	25.50	28.60
预测 (ANN)	12.50	29.10	11.30	13.30	10.00	29.80	11.30	21.60	29.50	28.30	29.00	22.50	12.90	25.40	20.10	20.20	25.20	27.10	14.90	21.20	16.80
最终预测	16.7084	21.2259	19.18	22.9335	20.1302	20.6713	18.6771	20.8387	27.9778	27.2423	21.968344	23.7421	19.0089	24.9235	17.8373	22.4234	26.8856	23.7392	18.4807	24.5558	20.5788

401

图4




图5