

基于分形维的决策树构建及应用研究

李广水¹, 郑滔², 孙梅¹

(1. 金陵科技学院, 江苏 南京 211169;

2. 南京大学软件学院, 江苏 南京 210093)

摘要:针对决策树构建过程中易于出现数据碎片、子树重复等问题,提出了基于分形维构建特征数据集的方法:因为信息增益表示了该属性信息量的多少,因此在确定了数据集的嵌入维数 k 之后,选择信息增益最大的前 k 个属性构造原数据集的特征数据集,并分析了依据分形维数和信息增益对冗余属性的删除以及特征集的信息损失对决策树构建的影响。实验过程中,分别采用从原始属性中选择及拟合两种方法构建特征数据集,依据对实验结果的比较分析,进一步证明了该方法的有效。

关键词:决策树;分形维数;信息增益;数据挖掘

中图分类号:TP311

文献标识码:A

文章编号:1673-629X(2009)12-0005-04

Research of Decision Tree Design and Application Based on Fractal Dimension

LI Guang-shui¹, ZHENG Tao², SUN Mei¹

(1. Jinling Institute of Technology, Nanjing 211169, China;

2. Software Institute, Nanjing University, Nanjing 210093, China)

Abstract: For the key issues that how to reduce the data fragmentation and sub-tree repeat in training the decision tree, the concept to construct the characteristic data set basing on the fractal dimension are presented; selecting number k of all attributes ordered by information gain according the embedding dimension of the source data set, the method of dropping the redundancy attributes and the infection of information loss to decision tree is discussed. In the experiment, the decision trees are trained on different characteristic data sets that one is by directly selecting some attributes from source data set and another is made up, analysing the results from two decision trees applied to test data set proves the method is effective.

Key words: decision tree; fractal dimension; information gain; data mining

0 引言

决策树归纳的基本算法是贪心算法,采用自顶向下的各个击破的方式构建,因此决策树归纳容易出现“数据碎片”,即随着树的生长,可以参与判断的元组越来越少,导致对于偏右底层的叶结点判断可能仅依赖于较少的记录,从而不能作出统计意义上的判断。另一个方面,太多的属性特别是冗余属性和相对较少的记录集还会导致决策树生长出现过分拟合,看似训练良好的决策树在测试过程中表现误差却很大^[1]。

决策树终止的条件常常是所有的属性都参与了样

本的划分,这常使得决策树过于复杂且难以解释,贪心算法采用的分而制之的策略可能在不同的分枝下使用相同的测试条件,从而导致树重复问题,过多的冗余属性将导致分枝增多,也会使得子树重复的概率加大。

因此,在构建一个决策树前对属性集的冗余属性进行约减,是极其重要的一步。

1 相关研究

在属性约减研究中,业已提出了多种解决方法,如数据独立性选择方法、卡方统计选择法、投影追踪回归、主成分分析、人工神经网络,而基于分形维数的属性约减除了反映了数据固有特性以外,可以精确地估算出数据集的本质维数。

分形理论是现代非线性科学研究中十分活跃的一个数学分支,它的基本思想是利用整体与局部相似的

收稿日期:2009-04-24;修回日期:2009-07-08

基金项目:国家高技术研究发展计划项目(863/2007AA01Z448);江苏省社会科学基金(08TQB007)

作者简介:李广水(1965-),男,博士,高级工程师,副教授,研究方向为数据挖掘、信息系统集成。

特点,将一个复杂现象看成是由简单现象迭代而成,从而揭示复杂现象中所蕴含的规律和特性,特别适合于解决复杂问题,在处理非线性问题中得到了广泛的应用^[2]。对于具有分形特征的物体而言,分形维数是一个重要的指标,它能够定量地描述分形集的复杂程度。分形理论在数据集的属性规约过程中被广泛采用,文献[3~5]提出了基于分形维的属性约减算法,其基本思想是将数据集合的嵌入属性依据分形理论尽量约减到其固有维数,文献[6]依据分形理论对无监督属性约简及结果属性的选择进行了探讨,并从算法的时空复杂性做了初步分析,文献[7]综述了分形理论在信号的仿真建模、复杂背景中的目标检测、故障诊断、语音信号处理及生物信号处理中的应用和研究成果及未来发展趋势。

设数据集 $s = \{A, E, d\}$, 其中 A 表示拥有 p 个属性的属性集 $\{A_1, A_2, \dots, A_p\}$, d 表示分类属性, E 表示包含 n 个元组的对象集, 依据 Traina 等人^[3] 的研究, 如果将 E 映射到 p 维空间, 并将每一维 $1/r$ 等分 ($r = 1/2, 1/4, 1/8, \dots$) 后得到 $(1/r)^p$ 个单元格, 依属性集顺序从 0 开始编号每一个 p 维单元格, 则第 i 条记录 $R_i = \{R_{i1}, R_{i2}, \dots, R_{ip}\}$ 在 p 维空间中落入的单元格顺序编号可以基于 $(R_{i1}/R_1, R_{i2}/R_2, \dots, R_{ip}/R_p)$ 得到, 其中 R_1, R_2, \dots, R_p 分别为数据集的属性 A_1, A_2, \dots, A_p 的值域范围被 $1/r$ 等分之后的数值, 记第 i 个单元格落入的点数为 $C_{r,i}$, 令 $S(r) = \sum_i (C_{r,i})^2$, 则数据集的分形维数可以定义为:

$$D(s) = - \frac{\partial \log(S(r))}{\partial \log r} \quad (1)$$

对于自相似的数据集, 式(1) 是常数, 而对于实际数据集, 在以 $\log r$ 为横坐标, 以 $\log(S(r))$ 为纵坐标的两维坐标系统中描点, 其曲线的近似斜率即为数据集的分形维。研究证明数据集的分形维数是数据集的固有维数的一个精确度量^[3,5,6]。

2 分析路径

利用分形维数确定数据集的固有维数 $k(k < p)$, 依据记录集 s 导出 $s' = \{A', d, E'\}$, 其中 $A' \subset A$, 且 A' 的势等于 k , 记 s' 为 s 的特征数据集。显然基于特征集 s' 构建的决策树深度将不会大于 k , 不仅可以防止子树重复, 且可以减少数据碎片及过分拟合。以下讨论特征集 s' 的构造方法, 并分析基于 s' 训练的决策树可以保证较好的准确率和更好的鲁棒性。

2.1 基于信息增益的决策树构建

信息增益是衡量属性信息量的大小, 量化了该属性的类别判别能力^[8]。基于信息增益的决策树训练是

最常用方法之一。

在一个对已经分类(共 m 个类)的数据集(共有 n 个)中, n 中包含 n_i 个 C_i 类样本, 其中 $i = 1, 2, \dots, m$ 。一个任意样本属于 C_i 的可能性是 n_i/n , 对一个给定的

样本分类所期望的信息为: $I(n_1, n_2, \dots, n_m) = - \sum_{i=1}^m \frac{n_i}{n} \log_2 \frac{n_i}{n}$, 具有值 $\{a_1, a_2, \dots, a_v\}$ 的属性 A 可以用来将

n 划分为子集 $\{n_1, n_2, \dots, n_v\}$, 其中, n_j 包含 n 中 A 值为 a_j 的那些样本。设 n_j 包含类 C_i 的 n_{ij} 个样本, 依据 A 的这种划分的期望信息称为 A 的熵, 其加权平均:

$E(A) = \sum_{j=1}^v \frac{n_{1j} + \dots + n_{mj}}{n} I(n_{1j} + \dots + n_{mj})$, A 上该划分获得的信息增益定义为:

$$\text{Gain}(A) = I(n_1, n_2, \dots, n_m) - E(A) \quad (2)$$

依据信息增益的决策树构建的基本算法如图 1 所示。

```

Input training set having p test-attribute as {a1,a2,...ap}
Output one decision tree
procedure:
  creat node n
  if set in same class C then
    return N as leaf of the tree and label C as class
  if no element from attribute-list then
    return n as leaf of the tree and label with general class
  select the most gain from the all gain that calculate every at-
  tribute from test-attribute
  label node n as test-attribute
  for i=1 to p{
    set a new divarication that fits test-attribute=a(i)
    set sub-set is the from the trining-set that test-attribute =
    {ai}
    if sub-set is null
      generate a leaf and label with general class
    else
      creat another node that from training set having test-at-
      tribute-left //drop {ai}
  }

```

图 1 依据信息增益的决策树构建方法

由以上算法可以看出, 为了提高决策判断力, 在决策树构建过程中, 总是从剩余属性中选择信息增益最大的属性进行类别判断, 虽然少量的冗余属性对决策树的构建不会产生大的影响, 但过多的冗余属性会导致决策树过于庞大, 并且极易产生子数重复问题, 这无论从算法的角度还是从决策树本身的效率都应该尽量避免。特别地, 在将原 p 个属性集归约到 k 个属性之后, 存在于特征集 s' 中的冗余属性将更可能参与决策树训练, 因此在从数据集的 p 个原始属性选择 k 个最终属性之前, 应首先删除冗余属性。

2.2 相关属性分组

作为对类别判别能力的一个衡量, 信息增益并不

能表达属性之间的相关程度,因此,不能作为冗余属性的判断依据。

设属性 $A_i, A_j \subset A$, 记 $D(A_i), D(A_j)$ 为单个属性 A_i 和 A_j 的分形维数,依据分形维的计算定义,单个属性的值可以描绘出一维上不同位置的点列,为便于对比,可以将 A_i, A_j 的值域映射到相同的区间,则 A_i, A_j 的相关程度直接可以反映在点列的相似程度上,也直接决定了 $S(r)$ 的数值。特别的,如果 A_i, A_j 完全线性相关,则分列于一维上的每一对覆盖 A_i 值和 A_j 值的单元格中的点数是完全对应相等的,即 $S(r)$ 相等,从而 $D(A_i) = D(A_j)$ 。因此,可以认为,属性的分形维数的大小能够作为属性相关性的度量。

在具体数据集特别离散值的处理过程中,为了防止单独属性在计算分形维过程中出现“点列团聚”,可以采用以下更为一般的处理方式计算单个属性的分形维数。

设属性 $A_i, A_j \subset A$, 记 $D(s/A_i)$ 为数据集 $s = \{A/A_i, E, d\}$ 的分形维数,其中 $A/A_i = A - \{A_i\}$, 定义:

$$D'(A_i) = D(s) - D(s/A_i) \quad (3)$$

$D'(A_i)$ 存在以下三种情况:

若 $\{A_i\}$ 与 $A - \{A_i\}$ 中的属性组合强相关,则 $D'(A_i) \cong 0$ (4)

若 $\{A_i\}$ 与 $A - \{A_i\}$ 中的所有属性组合都无关,则 $D'(A_i) \cong D(A_i)$ (5)

若 $\{A_i\}$ 与 $A - \{A_i\}$ 中的所有属性组合都弱相关或无关,则 $0 < D'(A_i) < D(A_i)$ (6)

并且, $D'(A_i)$ 与 $D'(A_j)$ 可以作为属性相似程度的一个衡量^[6]。另一方面,若 $\{A_i\}$ 和 $\{A_j\}$ 属性强相关,由(4)可知,将有 $D'(A_i) \cong D'(A_j) \cong 0$, 因此,在以 $D'(A_i)$ 代替 $D(A_i)$ 进行冗余属性讨论过程中,还必须考虑 $D'(A_i)$ 接近 0 的程度。简单的说,如果两个属性的分形维数很小并且数值接近,则两个属性之间相似度很高,存在冗余。

若集合 $D = \{D'(A_1), D'(A_2), \dots, D'(A_p)\}$, 记 δA_i 为属性 A_i 相对于 D 的与 0 接近程度,定义:

$$\delta A_i = e^{mD - D'(A_i)} \quad (7)$$

其中 $mD = \text{Max}\{D'(A_1), D'(A_2), \dots, D'(A_p)\}$ 。

因此,为删除冗余属性,在得到数据集 s 的分形维数 k 之后,对于每一个属性 $\{A_i\}$, 首先利用式(3)计算其分形维数 $D'(A_i)$, 再依据式(7)计算其 δA_i , 这样每个属性有两个分量 ($D'(A_i), \delta A_i$) 参与属性集聚类运算,其完整算法描述如图 2 所示。

该算法需要扫描数据库 $n(p+1)$ 次,在 n 远大于

p 的情况下,其时间复杂度为 $O(n)$ 。

```

Input Training Set S, having p attributes, k as cluster number,
Output k similar attribute sets (k < p)
Procedure:
  for i=1 to p
    calculate the  $D'(A_i) = D(s) - D(s/A_i)$ 
  let  $mD = \text{Max}\{D'(A_1), D'(A_2), \dots, D'(A_p)\}$ 
  for i=1 to p
    calculate the  $\delta A_i = e^{mD - D'(A_i)}$ 
  random choose k  $\{A_i\}$  as the initial cluster center
  repeat
    assign the each residual attribute to its nearest cluster
    calculate new center of each cluster
  until the every center position keeps invariable
  
```

图 2 依据属性之间的相似程度将属性集进行聚类

2.3 生成特征数据集

在特征集生成过程中,依据式(2)定义,需要计算出每一个属性的信息增益,再从 k 组中分别选出每组信息增益最大的 k 个属性组成新的属性集 A' 。

依据数据集的固有维数强制决策树训练的深度,会丢失有益于类判别的部分属性,下面讨论其损失的信息量相比特征集保留的信息而言应是很少的。

缩减属性后的数据集将可能会出现相同及矛盾元祖(即在全部属性上有相同数据但决策属性上数据不同),可以认为相同元祖的多少表现为冗余属性对数据集影响的大小,而矛盾元祖代表了损失信息的多少,会直接导致训练误差。对相同及矛盾元祖的处理方法可以将多个相同元祖归类为一个,矛盾数据依据多数得票法归类,相同得票数的进行随机分配。

矛盾数据的多少反映了被删除属性对类别的判别能力,而对于一个具有分形特征的数据集,由于分形维数直接反映了数据集的本质特征,因此基于其固有维数确定的特征集的属性个数理论上可以满足对决策属性的正确判别,而依据信息增益对结果属性的选择方式将选出具有最佳决策数据的判别能力的候选属性,因此将不会出现太多的矛盾数据。

3 应用检验与分析

在研究农民科技学习状况所进行的调查分析中,希望从相关调查信息获得影响农民科技学习的主客观因素及其影响率,初始一千份调查表依据逐个访谈及与其所在地方部门相关单位的沟通,甄别出被调查农民依据科技学习对现状及未来的影响。为了下一步大范围基于网络分析服务,需要构建一个可以依据面上调查数据正确判断的分类器,以此实现动态决策分析。

调查数据包含了相关个人能力、家庭情况、政府措施等 21 个基础数据和一个决策数据,调查数据绝大部

分采用选项方式,少量数据可以经过层次概化归类至相应的范围,其部分数据见表 1。原始调查数据中有 17 个重复数据,合并后得到有效数据为 984 个,并将其分为 700 条训练数据记录和 284 个测试记录。

表 1 农民科技学习调查数据

| 调查数据项 | 文化程度 | 从业类型 | 年收入 | 家庭结构 | 农业技能 | 工业技能 | ... |
|-------|------|------|-----|------|------|------|-----|
| 程序处理名 | A1 | A2 | A3 | A4 | A5 | A6 | |
| 离散值个数 | 3 | 6 | 连续 | 4 | 5 | 8 | |

采用一般 PC 机及 WindowsXP 系统,利用 VFP 数据库管理系统进行数据维护及程序设计,将分析结果导入 Excel 之中进行图表输出。VFP 具有良好的数据处理及程序设计能力,其数据表可以与 Excel 相互调用,是 PC 环境中方便实用的密集型数据处理工具。

取 $r = 1/2, 1/4, 1/8, \dots$ 共 300 个分割,利用式(1)分别在二维坐标上绘出 $\log r$ 和 $\log(S(r))$,计算出训练数据集和全部数据集的分形维数分别为 5.36 和 5.92(见图 3)。0.5 左右的差别也表明了数据具有良好的分形特性。选择 $k = 6$ 作为特征数据集个数。




图 3 训练集和全部数据集 300 次迭代下盒维走势

为了删除冗余属性,对所有 21 个属性进行了分形维计算及信息增益计算,并依据图 1 进行分组聚类,实验过程中采用传统的 k -平均法进行属性聚类,采用欧氏距离,选择其中每组信息增益最大的属性,形成 A' 数据集,得到的分组结果见表 2。合并之后的训练集中有 75 个元数据进行了数据合并,包括 62 个矛盾数据,最终构成特征数据集。

采用经典的 C4.5 决策树算法,依据特征数据集 s' 训练决策树,获得的分类规则在对测试集进行验证中获得 220 条正确分类,其正确率达到了 81%。

上面的实验过程中,形成新的数据集时出现了 10.7%(75/700)左右的重复数据及约 9%(62/700)的矛盾数据,而矛盾数据直接造成了决策树的训练误差达到了 9%,最终导致在测试数据集上精度不是非常理想。分析认为其中一个主要原因是在特征集 s' 构

造过程中,属性的选择是从每组中选择信息增益最大的属性而非整个剩余属性集中最大的属性,这一方法降低了基于 A' 的类别判断力。

表 2 分组后属性相关数据

| 属性代码 | 分形维数 | 0 接近度 | 信息增益 | 选择的属性 |
|------|-------|-------|-------|-------|
| A13 | 0.549 | 1.000 | 0.219 | a13 |
| A12 | 0.300 | 1.283 | 0.032 | |
| A6 | 0.260 | 1.335 | 0.236 | a6 |
| A18 | 0.221 | 1.388 | 0.088 | |
| A1 | 0.200 | 1.418 | 0.21 | |
| A15 | 0.193 | 1.428 | 0.188 | a15 |
| A20 | 0.160 | 1.476 | 0.019 | |
| A9 | 0.100 | 1.567 | 0.001 | a17 |
| A10 | 0.100 | 1.567 | 0.095 | |
| A3 | 0.082 | 1.595 | 0.039 | |
| A17 | 0.008 | 1.718 | 0.15 | |
| A19 | 0.012 | 1.711 | 0.02 | a4 |
| A16 | 0.014 | 1.707 | 0 | |
| A21 | 0.065 | 1.623 | 0.001 | |
| A14 | 0.017 | 1.702 | 0.01 | |
| A4 | 0.017 | 1.702 | 0.035 | |
| A2 | 0.025 | 1.689 | 0.269 | a2 |
| A11 | 0.053 | 1.642 | 0.113 | |
| A5 | 0.030 | 1.680 | 0.016 | |
| A8 | 0.049 | 1.649 | 0.06 | |
| A7 | 0.032 | 1.677 | 0.002 | |

为了验证以上的构想,在新属性集 A' 选择过程中,采用拟合的方法进行构建,具体方法是以表 2 的每组中每一个成员的信息增益为权重因子,选每组中离散个数最大值作为新属性的离散个数,这保证了能够非常好地拟合特征数据集,属性缩减之后几乎不出现重复数据和矛盾数据(本次验证中没有出现),基于该训练数据集生成的决策树在测试集上验证达到了近 95% 的正确率,这也进一步证明了基于分形理论在有监督分类中的价值。当然,该方法不能实际采用的主要原因除了构建决策树之前需要拟合所有训练数据集构成特征数据集,还需在验证之前对测试集数据进行拟合,这种反复扫描数据集的方法在海量数据处理过程中显然是不易被接受的,且不利于对决策树的直观理解。

4 结束语

探讨了基于分形理论的决策树构建,应用实验验证了文中提出的观念,而如何在可接受的算法时空复杂度的前提下提高分类精度将是下一步主要研究内容。作为分形理论在数据挖掘中的应用前提,判定一个数据集是否具有较好的分形特征是问题的关键,也是未来所关注的。

(下转第 12 页)

表 1 显示了实验结果,可以看出眼睛定位的正确率均在 96% 以上,误检率是达到了 3% 以下,这都充分体现了算法的高精确性。在定位时间方面,CAS-PEAL 库和 ORL 库均表现良好,能满足实时性的要求,其中 CAS-PEAL 库的定位时间少于 ORL 库,因为算法中的阈值设置(如投影后上下扩展的像素值),都是针对亚洲人的标准,所以定位时间稍快些。

表 1 实验结果

| | 眼部框选正确率 | 眼睛定位正确率 | 眼睛误检率 | 平均定位时间 |
|------------|---------|---------|-------|---------|
| CAS-PEAL 库 | 99% | 97% | 1% | 0.0416s |
| ORL 库 | 98% | 95.33% | 2.67% | 0.0938s |

5 结束语

文中采用了双向投影和动态阈值卷积的定位算法,其中双向投影法由于其固有的缺点,文中不直接用于定位眼睛,而作为框选双眼范围的粗定位。这样既避免了其对姿态变化敏感等缺点,又提高了粗定位准确性。动态阈值卷积法用于快速定位眼睛黑块,它能在保证定位准确度的情况下,动态求取最小阈值,极大地提高了算法的可靠性和鲁棒性。

实验表明,该算法速度快,准确率高,适应性强,对不同的人,不同的光照变化,一定程度的头部、脸部旋转,及睁闭眼和戴眼镜等情况均有较好的定位效果。但算法也存在一定局限性,如当头发部分遮住眼睛,头部旋转角度过大,眉眼间距过短及戴墨镜等情况,会对算法造成影响,导致定位出错,这有待于今后作进一步的研究。总体上讲,该文的算法对图像要求不高,且实时性强,易于实现,因而在疲劳驾驶监控等领域有较好的应用价值。

参考文献:

[1] Yuille A, Cohen D, Hallinan P. Feature extraction from faces

using deformable templates[J]. International Journal of Computer Vision, 1992, 8(2):100-104.

[2] Kawaguchi T, Hidaka D, Rizon M. Detection of eyes from human faces by hough transform and separability filter[C]//Proceedings of IEEE International Conference on Image Processing. Vancouver BC: IEEE Computer Society, 2000:49-52.

[3] Ma Yong, Ding Xiaoqing, Wang Zhengeng, et al. Robust precise eye location under probabilistic framework[C]//the Sixth IEEE International Conference on Automatic Face and Gesture Recognition. Seoul: [s. n.], 2004:339-344.

[4] 耿新,周志华,陈世福.基于混合投影函数的眼睛定位[J].软件学报,2003,14(8):1394-1400.

[5] Liu X, Xu F, Fujimura K. Real-time eye detection and tracking for driver observation under various light condition[C]//IEEE Intelligent Vehicle Symposium. Versailles, France: [s. n.], 2001:18-20.

[6] Reisfe - Id D, Yeshurun Y. Robust Detection of Facial Features by Generalized Symmetry[C]// Pattern Recognition, 1992. Vol. I. Conference A: Computer Vision and Applications, Proceedings. 11th IAPR International Conference. The Hague, Netherlands: [s. n.], 1992:117-120.

[7] Gao Wen, Cao Bo, Shan Shiguang, et al. The CAS-PEAL Large-Scale Chinese Face Database and Baseline Evaluations[J]. IEEE Trans. on System Man, and Cybernetics (Part A), 2008,38(1):149-161.

[8] 孙晓玲,侯德文,储凡静.人脸识别中的眼睛定位方法[J].计算机技术与发展,2008,18(10):46-49.

[9] 江水郎,杨明.面向驾驶员疲劳检测的双空间人眼定位方法[J].计算机工程,2008,34(24):180-182.

[10] Haralick, Shapiro. Computer and Robot[M]. [s. l.]: Addison - Wesley, 1992:59-83, 639-658.

[11] Jesorsky O, Kirchberg K J. Robust face detection using the Hausdorff distance[M]//In: Bigunand J, Smeraldi F. Audio and Video - based Person Authentication. Lecture Notes in Computer Science. Berlin: Springer - Verlag, 2001:90-95.

(上接第 8 页)

参考文献:

[1] Ning Pang, Michael T, Kumar S V. 数据挖掘导论[M]. 范明, 范宏建, 等译. 北京:人民邮电出版社, 2006:105-116.

[2] 李水根. 分形[M]. 北京:高等教育出版社, 2004:80-99, 115-138.

[3] Traina Jr c, Traina A. Fast fetures selection using fractal dimension[C]//Proc of XV Brazilian Database Symposium on Database. Berlin: Springer, 2000:158-171.

[4] 鲍玉斌,王琢,孙怀良,等.一种基于分形维的快速属性

选择算法[J].东北大学学报,2003,24(6):527-530.

[5] 郭平,陈其鑫,王燕霞.基于分形维数的属性约减[J].计算机科学,2007,34(9):189-190.

[6] 闫光辉,李怀战.两阶段无监督顺序前向分形属性规约算法[J].计算机研究与发展,2008,45(11):1955-1964.

[7] 贾丽会,张修如.分形理论及在信号处理中的应用[J].计算机技术与发展,2007,17(9):203-205.

[8] Han Jiawei, Kamber M. 数据挖掘概念与技术[M]. 范明, 孟小峰, 等译. 北京:机械工业出版社, 2005:122-136, 180-192.