

文章编号:1671-1637(2013)03-0107-06

铁道信号系统安全计算机状态监测方法

曹源^{1,2}, 马连川^{1,2}, 李旺³

(1. 北京交通大学 轨道交通运行控制系统国家工程研究中心, 北京 100044; 2. 北京交通大学 电子信息工程学院, 北京 100044; 3. 山东省计算中心, 山东 济南 250014)

摘要:基于隐马尔科夫模型(Hidden Markov Model, HMM)提出了状态监测和故障诊断的原理与基本流程。通过观测数据的提取与降维, 正常态模型训练与改进, 故障态模型训练等一系列措施, 实现了两模冗余安全计算机的状态监测, 对正常态与时钟偏离1%~10%等7种不同条件进行监测。监测结果表明:对数似然概率均值从-228.98降至-1385.60, 健康状态不断恶化。对1号处理单元(PU1)故障状态进行仿真监测时, 将PU1故障与PU1故障态、正常态、安全容错管理单元(FTSM)故障态、通信控制器(CC)故障态以及系统受扰故障态进行比较, 得到对数似然概率均值分别为-161.95、-13.72、-14.13、-40.17及-35.69, 证明了系统所发生的故障是因PU1所致。监测方法能够有效实现安全计算机健康状态的检测, 为铁道信号安全计算机监测技术提供理论支撑。

关键词:铁道信号; 系统安全; 隐马尔科夫模型; 故障监测; 健康管理

中图分类号:U283.2 **文献标志码:**A

Monitoring method of safety computer condition for railway signal system

CAO Yuan^{1,2}, MA Lian-chuan^{1,2}, LI Wang³

(1. National Engineering Research Center of Rail Transportation Operation and Control System, Beijing Jiaotong University, Beijing 100044, China; 2. School of Electronic and Information Engineering, Beijing Jiaotong University, Beijing 100044, China; 3. Shandong Computer Science Center, Jinan 250014, Shandong, China)

Abstract: The principle and primal procedure of condition monitoring and fault detection were proposed based on hidden Markov model (HMM). The condition monitoring for two-mode redundant safety computer was carried out by using a number of ways, including the extraction and dimensionality reduction of observed data, the training and improvement of normal status model, the training of fault status model and so on. 7 different conditions of normal statuses and statuses with 1%-10% clock offsets were monitored. Monitoring result shows that average logarithmic likelihood probability reduces from -228.98 to -1385.60, which indicates the degrading of health status. When the monitoring of PU1 (process unit 1) faults is conducted by simulation, the average logarithmic likelihood probabilities of fault status compared with PU1 fault, normal status, fault tolerance and safety management (FTSM) fault, communication controller (CC) fault, and system interference fault are -161.95, -13.72, -14.13, -40.17 and -35.69, respectively, which verifies that the system fault is resulted from PU1. So the proposed monitoring method is effective in safety computer monitoring, and it will give a

收稿日期:2012-12-18

基金项目:国家863计划项目(2012AA112001, 2012AA112801); 中央高校基本科研业务费专项资金项目(2012JBZ014); 高等学校博士学科点专项科研基金项目(20110092120011, 20120009120004); 国家自然科学基金项目(61101087); 铁道部科技研究开发计划项目(2013X013-D)

作者简介:曹源(1982-), 男, 河南开封人, 北京交通大学讲师, 工学博士, 从事高速铁路通信信号研究。

theoretical support to the monitoring of railway signal safety computer. 7 figs, 15 refs.

Key words: railway signal; system safety; hidden Markov model; fault monitoring; health management

Author resume: CAO Yuan(1982-), male, lecturer, PhD, +86-10-51684971, ycao@bjtu.edu.cn.

0 引 言

铁道信号系统是一个典型的安全苛求系统,安全计算机作为铁道信号系统的核心部件,一旦发生故障将会导致信号系统的崩溃和瘫痪,直接威胁铁路系统行车安全^[1]。对安全计算机故障维修的研究目前还停留在传统的定期维修和事后维修阶段,这些方式很难预防故障的突然发生,存在维修损坏的风险。视情维修策略能够有效保障安全计算机平台安全性,但是如何实现对安全计算机的在线监测和管理是困扰视情维修的一个难题^[2]。视情管理技术首先成功应用于飞行器发动机等机械系统中,也使得人们预期其在电子产品的维修和保障方面同样具有良好的应用前景。Vichare 等在 F35 战斗机电子设备上应用视情维修的理念,就是从传统的基于传感器的诊断转向基于智能系统的预测,在一定程度上代表了维修方法的转变^[3]。

隐马尔科夫模型(Hidden Markov Model, HMM)是一种基于时间序列统计的模型,具有较强的模式分类能力,能够对一段时间跨度上的数据信息进行分类和建模,适合处理连续动态信号^[4]。Smyth 等使用 HMM 网络数据进行了状态监测^[5];华盛顿大学的 Atlas 等使用 HMM 对工具磨损状态进行了实时监测^[6];美国凯斯西储大学的 Ocack 等提出了基于振动信号的 HMM 在轴承故障诊断中的应用^[7]。此外, HMM 也被美国马里兰大学的先进寿命周期工程中心认定为视情维修技术的经典模型之一。

但对于基于计算机的电子系统监测与管理系统,基于 HMM 的方法主要应用于民航领域整机或发动机的性能状态监控等。对铁路领域电子产品的健康管理技术的研究尚在起步阶段,尤其是针对安全苛求系统的安全计算机,没有相关研究。本文通过建立基于 HMM 的安全计算机监测方法,实现对铁道信号安全计算机故障状态监测与管理,为其视情维修提供理论依据。

1 隐马尔科夫模型

HMM 是由 Markov 链发展而来的, Markov 链

是一个离散随机过程,其特性是在已知目前状态条件下,它未来的演变不依赖于过去的演变,在每个时刻,系统都只处于一种状态,且每种状态对应一个观测值^[8]。虽然类似于一阶 Markov 过程,但 HMM 是一个双内嵌式随机过程,由 2 个随机过程组成,一个为具有有限状态 Markov 链的状态序列,描述状态的转移,另一个为受状态决定的观测值序列。HMM 中不仅状态转移是随机过程,每个状态对应的观测值也是一个随机过程,其中观测值序列可以直接看到,而状态转移序列只能通过观测值序列去判定,即其状态是不确定或不可见的,因此称为 HMM^[9-11]。

HMM 包括具有状态转移概率的 Markov 链和输出观测值的随机过程,记为 λ , 由一个五元组 (N, M, π, A, B) 组成, N 为模型中 Markov 链的状态数目, M 为每个状态对应的可能的观测值, π 为初始概率分布, 为一个 N 维的矢量, A 为状态转移概率, 与 HMM 的状态数 N 有关, 为一个 $N \times N$ 阶的矩阵, B 为观测值概率, 与 HMM 的状态数 N 以及可观测值数 M 有关, 为一个 $N \times M$ 阶的矩阵。

针对铁道信号安全计算机的状态监测,一般采用基于 HMM 的训练模型。训练中的问题在于模型参数未知或不准确的情况下,如何根据观测序列 O 求得模型参数或调整模型参数,即解决如何通过一组观测序列在最大似然意义上训练得到一个 HMM 的参数,通常使用 Baum-Welch 算法训练^[12]。Baum-Welch 算法实际上是极大似然(ML)准则的一个应用,采用一种多次迭代的优化算法。为解决利用观测序列训练 HMM,记观测序列的概率为 $P(O|\lambda)$, 其中 λ 为 HMM 经训练后的新模型,记初始 HMM 为 λ_0 。为使 $P(O|\lambda)$ 最大,首先估计一个初始 λ_0 , 通过前向-后向算法计算 $P(O|\lambda_0)$, 然后通过使期望值最大化再次进行模型的训练得到新的模型 λ , 如果新得到的 λ 满足 $P(O|\lambda)$ 与 $P(O|\lambda_0)$ 的差不大于收敛阈值,训练得到了预期效果,算法结束,否则令 λ 作为 λ_0 反复进行迭代运算,直到达到收敛条件^[10,13]。作为 Baum-Welch 算法的前提,通过前向-后向算法采用穷举所有可能的状态转换序列的办法计算观测序列 O 的概率,使得计算量呈几

何级数增加。为了降低计算复杂度,前向和后向概率算法将整个观察序列对 HMM 的输出概率分成 2 部分观测序列输出概率的乘积,这样大幅简化了计算量^[14]。

2 基于 HMM 的安全计算机平台状态监测原理

安全计算机作为一个典型的电子系统,其状态情况是隐藏的,很难直接监测,能观测到的通常是其所表现出来的与状态相对应的信号特征,因此,只能依靠这些信号特征去推理系统的状态,而利用 HMM 可以很好地描述安全计算机的状况变化情况。本文通过对铁道信号安全计算机的分析,基于 HMM 对安全计算机进行描述和建模,并提出基本的状态检测原理。

2.1 安全计算机结构

铁道信号安全计算机的故障程度随使用时间的增加而逐渐发展,从正常态到故障态具有不可逆性,因此采用 HMM 基本结构之一的从左到右型 HMM 结构来进行状态监测和故障诊断。图 1 将安全计算机的状态分为 4 类:正常态(0)、弱故障态(1)、中间故障态(2)、完全故障态(3),图中 a_{ij} ($i, j = 0, 1, 2, 3$) 为状态转移概率矩阵中的元素, O_k ($k = 0, 1, 2, 3$) 为与各状态对应 HMM 观测序列。可见,从左到右型 HMM 可以真实反映系统正常态不断劣化和故障发展的不可逆性,并最终发展为完全故障的过程。




图 1 HMM 结构

Fig. 1 HMM structure

安全计算机在工作开始时,一般认为总处于正常工作状态下,从而初始概率分布矢量 π 为(1,0,0,0),状态转移概率 A 能够反映过程状态序列相关信息,在初始时刻一般设为均匀分布或非随机数。状态转移概率 A 为

$$A = \begin{bmatrix} a_{00} & a_{01} & 0 & 0 \\ 0 & a_{11} & a_{12} & 0 \\ 0 & 0 & a_{22} & a_{23} \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

2.2 状态监测原理

利用 HMM 进行安全计算机状态监测的过程分为 3 步。

Step 1:历史数据的特征提取与预处理。数据特征的提取是状态监测的重点。一般从安全计算机的输出响应提取合适的观测数据,并进行多次提取。观测数据一般具有冗余和高维的特点,直接进行状态监测,计算开销大,检测效率低,因此,需对观测数据进行预处理,以实现更高效、精确的状态监测。所提取的正常态以及故障态观测数据作为重要的参考,通过与提取安全计算机当前观测数据的比较,推断当前系统的状态。

Step 2:正常态与故障态 HMM 的训练。为了保证训练得到的 HMM 的稳定性,训练时采用多组观测序列重估算法,需要对多次观测数据进行重新组合,以固定次数的观测数据构成一个观测序列,得到多组观测序列。从正常态的观测序列中随机选取若干组,进行正常态 HMM 的训练。对故障态观测数据,需要训练系统所有的故障态 HMM,构成系统的故障监测库。

Step 3:状态监测。将当前测得的状态观测序列送入正常态的 HMM 中,由此可以根据前向-后向算法计算出正常态下产生待测观测序列的似然概率,从而判断系统当前状态的优劣。与正常态 HMM 的似然概率越大,说明系统的健康程度越高。如果发生故障,可以通过与故障态下的 HMM 的似然概率比较决定系统当前的故障模式和类型。

3 基于 HMM 的安全计算机状态监测实现

安全计算机作为复杂的电子产品,其安全状态或者故障状态不能以简单的元器件的进行近似,需要对计算机设备进行整体的状态监测,因此,本文选用处理时间作为安全计算机的处理时间,作为判据的基准。安全容错管理单元(Fault Tolerance and Safety Management, FTSM)是安全计算机与一般冗余计算机最根本的区别。由于两模冗余安全计算机结构简单,安全可靠性较高,是最具代表性的安全计算机之一,本文以两模冗余安全计算机的 FTSM 单元处理为例进行分析。

FTSM 上电后,启动初始同步定时,向 FTSM 发送初始同步确认信号,FTSM 进行两机同步。FTSM 模块将正常工作周期分为 3 个微周期:输入数据微周期,区域控制器(Zone Controller, ZC)应用微周期,输出数据微周期。安全计算机正常工作

与数据采集流程见图 2, PU1、PU2 分别为 1 号处理单元 (Processor Unit 1, PU1) 与 2 号处理单元 (Processor Unit 2, PU2); CC 为通信控制器 (Communication Controller, CC)。在每个微周期的开始时设定微周期同步定时钟, 结束时检查同步请求信号。同步成功后, 进入下一个微周期阶段。在输出数据微周期结束后, 经短暂延时, 系统周期循环工作。从电子设备的物理失效原理、安全计算机对实时的苛求性等因素, 选取 FTSM 模块的 3 个微处理周期的实际消耗时间作为状态观测数据是研究其正常态与故障态的最佳选择。

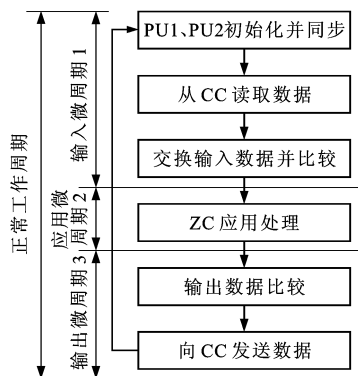


图 2 工作流程

Fig. 2 Working process

3.1 观测数据的提取与降维

本文假设时钟频率 $1\,000\text{ tick} \cdot \text{s}^{-1}$ (基于 VxWorks 操作系统, tick 为基本轮转的时间片单位) 为正常态情况, 分别选取系统时钟偏差 1%、2%、3%、4%、5% 和 10% 的数据, 模拟系统的不同状态。提取每个工作周期的 3 个微周期态进行状态监测, 每个周期都将得到 1 个三维数组, 多个周期形成的多个三维数组就是最初的观测数据。进行状态监测时选取正常态模式以及 4 种故障状态模式, 即 PU1 因干扰导致系统故障模式 (PU1 故障模式)、FTSM 因干扰导致系统故障模式 (FTSM 故障模式)、CC 因干扰导致系统故障模式 (CC 故障模式)、整个仿真安全计算机因干扰导致系统故障模式 (整体故障模式)。

由于提取的数据具有冗余和高维的特点, 直接利用 HMM 进行处理会极大降低推断状态信息的能力, 且计算量巨大, 同时为了便于数据的存储和传输, 需要对原始观测序列进行特征降维处理。采用经典识别算法线性判别式分析 (Linear Discriminant Analysis, LDA) 来处理原始状态数据, 可以达到很好的效果。LDA 的基本思想是将高维的模式样本投影到最佳鉴别矢量空间, 以达到抽取分类信息和

压缩特征空间维数的效果, 投影后保证模式样本在新的子空间有最大的类间距离和最小的类内距离, 减少了原始样本数据的维数, 实现特征的有效抽取^[15]。本文将观测数据进行了 LDA 降维, 使 1 个三维数组处理后成为 1 个一维的降维数组, 不仅起到降维的目的, 还能获得良好的分类效果。图 3 为 4 000 个正常态的三维数据进行 LDA 降维后, 得到的一维数据。




图 3 LDA 处理后的一维数据

Fig. 3 One-dimension data after LDA

3.2 正常态 HMM 的训练与改进措施

观测值概率矩阵设为随机数。假设系统下一时刻, 系统处于当前状态和转移到下一状态的概率相等, 即状态转移矩阵为

$$\mathbf{A} = \begin{bmatrix} 0.5 & 0.5 & 0 & 0 \\ 0 & 0.5 & 0.5 & 0 \\ 0 & 0 & 0.5 & 0.5 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

安全计算机状态转移见图 4。




图 4 安全计算机的状态转移

Fig. 4 State transition of safety computer

利用 Baum-Welch 算法进行模型训练时, 前向-后向变量会出现下溢问题, 造成模型的训练精度降低, 并且可能发生算法的逻辑错误。需要在前向-后向变量迭代计算中增加比例因子, 然后在 $P(O|\lambda)$ 的计算中消去比例因子的方法, 从而有效避免下溢问题的出现。为了保证原有计算结果不被破坏, 需要在计算 $P(O|\lambda)$ 时做相应的处理, 此过程不再赘述^[13]。

修正处理后就可以避免前向变量和后向变量的下溢问题, 在用 Baum-Welch 训练 HMM 时, 增加的比例因子也会被消除。经过多次迭代训练, 模型输

出相似概率的变化小于某一值时,认为达到收敛条件,模型训练结束。经过多次迭代后,会得到一个与正常状态的观测数据最为吻合,即 $P(O|\lambda)$ 最大的HMM。

训练过程见图5,图中纵坐标为每次迭代后得到HMM输出的相似概率,为了避免相似概率值太小,采用对数形式。随着迭代次数的增加,HMM的相似概率逐渐增大,在第8步时,模型输出相对概率变化满足收敛条件,认为正常态HMM训练完毕。




图5 正常态与故障态训练曲线

Fig. 5 Training curves of normal and failure statuses

3.3 故障态 HMM 的训练

模拟故障态数据,依靠干扰源在不同时刻向该通用计算机发送干扰信号,然后采集故障态数据。根据收敛时间、计算复杂度以及收敛精度,以选取 10^{-4} 数量级为例,并作为HMM训练的收敛条件。

分别将PU1故障模式、FTSM故障模式、CC故障模式、整体故障模式进行LDA处理,构成观测序列。每一种模式中,随机选取观测序列进行HMM训练。

每一种模式下的样本数据经过多次迭代后,会得到一个数据与样本数据最为吻合,即 $P(O|\lambda)$ 最大的HMM。训练过程见图5,4种模式的训练模型最后都达到收敛条件,PU1故障模式需经过19次迭代训练,其他3种模式需要10次迭代训练。

3.4 系统的状态监测结果

3.4.1 正常态监测

正常态的HMM训练好后,把待测的观测序列输入训练好的正常态HMM,计算似然概率,以此推测对应的正常态。似然概率越大,证明仿真安全计算机的状态越接近正常态,反之就越偏离正常态。最大似然概率的减小意味着系统的健康恶化,更易发生故障。由于设备的早期故障过程非常微弱,似然概率特别小,此处也用对数似然概率反映系统偏

离正常态的程度。

将正常态剩余的观测序列、系统时钟偏差1%的观测序列、偏差2%的观测序列、偏差3%的观测序列、偏差4%的观测序列、偏差5%的观测序列、偏差10%的观测序列各50组分别作为第1~7组测试样本送入正常态的HMM,各进行5次测试,测试输出的对数似然概率见图6。




图6 正常态的对数似然概率

Fig. 6 Logarithmic likelihood probabilities of normal status

7组测试样本中正常态观测序列对数相似概率最高,可以认为正常态的数据与HMM最为接近。其余情况下观测序列的相似概率各不相同,随着系统时钟偏差的增大,似然概率逐渐降低,平均值从-228.98降至-1385.60,反映出状态的不断恶化过程,因此,HMM对系统不同状态具有良好的识别效果。

3.4.2 故障态监测

仿真安全计算机的故障状态诊断数据训练之后,就可以进行故障诊断测试。分别新提取5种模式下(包括正常态)多组观测序列,作为测试样本,进行故障诊断测试。5种模拟条件下,分别进行观测序列的测试,图7为其中将PU1受干扰导致系统故障的样本数据输入到故障诊断库后得到的似然概率。结果表明PU1因干扰导致系统故障的样本数据输入到PU1故障模式HMM得到的似然概率为-161.95,输入到正常态模式、FTSM模式、CC模式、系统受扰故障模式HMM得到的对数似然概率分别为-13.72、-14.13、-40.17、-35.69。样本数据输入到PU1因干扰导致系统故障模式HMM得到的似然概率最大,因此,可以认为提取样本数据时系统所处的故障是处理单元PU1因干扰导致的系统故障。

本文在实验室建立实物仿真平台,进行了大量的实际测量和数据采集。本文方法针对所采集的数




图 7 对数似然概率比较

Fig. 7 Comparison of logarithmic likelihood probabilities

据都能正确的进行正常态监测与故障监控,显示了其在安全计算机故障诊断中具有良好的效果。

4 结 语

本文针对安全计算机的状态监测问题,以视情维修为切入点,采用时间序列动态模型 HMM 为研究工具,研究安全计算机状态监测和故障诊断的技术方法,给出了具体的实现过程,最终结果显示本文方法具有良好的效果和可行性。

对于铁道信号安全计算机的状态监测,本文仅采用了 4 种故障模式进行分析,实际使用中可根据实际需要,应用更多的故障数据以完善安全计算机的状态监测。

参考文献:

References:

- [1] 曹 源,唐 涛,徐田华,等.形式化方法在列车运行控制系统中的应用[J].交通运输工程学报,2010,10(1):112-126.
CAO Yuan, TANG Tao, XU Tian-hua, et al. Application of formal methods in train control system[J]. Journal of Traffic and Transportation Engineering, 2010, 10(1): 112-126. (in Chinese)
- [2] 陈 珊,王太勇,王国锋,等.机械设备智能诊断与预测维修系统[J].西南交通大学学报,2003,38(5):540-543.
CHEN Shan, WANG Tai-yong, WANG Guo-feng, et al. Intelligent fault diagnosis, prediction and maintenance system of mechanical equipment[J]. Journal of Southwest Jiaotong University, 2003, 38(5): 540-543. (in Chinese)
- [3] VICHARE N M, PECHT M G. Prognostics and health management of electronics[J]. IEEE Transactions on Components and Packaging Technologies, 2006, 29(1): 222-229.
- [4] OWSLEY L M D, ATLAS L E, BERNARD G D. Self-organizing feature maps and hidden Markov models for

machine-tool monitoring[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2787-2798.

- [5] SMYTH P. Hidden Markov models and neural networks for fault detection in dynamic systems[C]//IEEE. Proceedings of Neural Networks for Signal Processing. Boise: IEEE, 1993: 582-592.
- [6] ATLAS L, OSTENDORF M, BERNARD G D. Hidden Markov models for monitoring machining tool-wear[C]//IEEE. Proceedings of the Acoustics, Speech, and Signal Processing. Istanbul: IEEE, 2000: 3887-3890.
- [7] OCAK H, LOPARO K A. A new bearing fault detection and diagnosis scheme based on hidden Markov modeling of vibration signals[C]//IEEE. Proceedings of the Acoustics, Speech, and Signal Processing. Salt Lake City: IEEE, 2001: 3141-3144.
- [8] ZHAO Yun-xin, ATLAS L E, ZHUANG Xin-hua. Application of the gibbs distribution to hidden Markov modeling in speaker independent isolated word recognition[J]. IEEE Transactions on Signal Processing, 1991, 39(6): 1291-1299.
- [9] 林果园,郭山清,黄 皓,等.基于动态行为和特征模式的异常检测模型[J].计算机学报,2006,29(9):1553-1560.
LIN Guo-yuan, GUO Shan-qing, HUANG Hao, et al. An anomaly detection model based on dynamic behavior and character patterns[J]. Chinese Journal of Computers, 2006, 29(9): 1553-1560. (in Chinese)
- [10] 冯长建. HMM 动态模式识别理论、方法以及在旋转机械故障诊断中的应用[D]. 杭州:浙江大学,2002.
FENG Chang-jian. HMM dynamical pattern recognition theories, methods and applications in faults diagnosis of rotating machine[D]. Hangzhou: Zhejiang University, 2002. (in Chinese)
- [11] 王 剑,张 辉,蔡伯根,等.基于 HMM 的列车轨道占用自动识别算法研究[J].铁道学报,2009,31(3):54-58.
WANG Jian, ZHANG Hui, CAI Bai-gen, et al. The algorithm of automatic track occupying identification based on HMM[J]. Journal of the China Railway Society, 2009, 31(3): 54-58. (in Chinese)
- [12] QIAO Y, XIN X W, BIN Y, et al. Anomaly intrusion detection method based on HMM[J]. Electronics Letters, 2002, 38(13): 663-664.
- [13] 宋雪萍,马 辉,刘 杰,等.基于 HMM 的故障诊断特征提取和聚类技术[J].振动、测试与诊断,2006,26(2):92-96,157.
SONG Xue-ping, MA Hui, LIU Jie, et al. Feature extraction and clustering technique of rotating machinery fault diagnose based on HMM[J]. Journal of Vibration, Measurement and Diagnosis, 2006, 26(2): 92-96, 157. (in Chinese)
- [14] RABINER L R, JUANG B H. An introduction to hidden Markov models[J]. IEEE ASSP Magazine, 1986, 3(1): 4-16.
- [15] PECK R, NESS J. The use of shrinkage estimators in linear discriminant analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1982, 4(5): 530-537.