

基于 SOM 特征映射图上引力场的故障模式识别

陈文字¹ 刘井波^{1,2} 程小鸥¹ 孙世新¹

(电子科技大学计算机科学与工程学院 成都 610054)¹

(重庆三峡学院数学与计算机科学学院 重庆 404000)²

摘要 对聚类方法 SOM 特征映射图使用引力场进行区域划分,实现远程故障识别。首先由 SOM 得到输入模式的具有不同响应特性的聚类区域;对 SOM 特征图进行邻域相关性分析并使用阈值划分种子区域;以种子区域为引力源在 SOM 特征图中构造引力场,根据特征图中点沿在引力场所受力的方向运动而收敛到的种子区域进行区域划分,并以此进行模式识别。该方法不用考虑区域边界上点的分类问题且很容易扩展到多维空间。对 12 种典型飞机起落架故障进行远程检测仿真,取得了较满意的效果,较大地提高了正确识别率。

关键词 SOM, 引力场, 区域分割, 远程故障诊断

中图分类号 TP183 文献标识码 A

Fault Pattern Recognition Based on Gravitation Field of Self-organizing Feature Map

CHEN Wen-yu¹ LIU Jing-bo^{1,2} CHENG Xiao-ou¹ SUN Shi-xin¹

(School of Computer Science and Engineering, University of Electronic Science & Technology of China, Chengdu 610054, China)¹

(School of Mathematics and Computer Science, Chongqing Three Gorges University, Chongqing 404000, China)²

Abstract This paper proposed the Remote Fault Diagnosis based on Gravitation Field of Self-Organizing Feature Map (SOM). In order to find the region of different response characteristic, the input vector can be processed by SOM. This Gravitation Field method only uses the position characteristics of the regions of SOM to find their central seeds, and then construct gravitation field by employing the central seeds as gravitation origin. The convergent region of dot which moves along the direction of gravitation field in SOM is looked as region segmentation. Furthermore, the method needn't consider the classification of boundary point and easy to be extended to n-dimensional situation. The proposed methods had been successfully evaluated using twelve different datasets, and had greatly improved the rate of correct classification.

Keywords SOM, Gravitation field, Region segmentation, Remote fault diagnosis

1 引言

随着科学技术的发展,各种设备越来越复杂,经济的全球化导致设备的用户地域分布越来越广泛,设备制造商传统的技术支持和设备维护方法无法满足用户的要求。远程故障诊断是综合了设备链接、信息集成、人工智能^[1]、计算机网络与通信等学科;在处于不同地理位置的设备上建立状态监测点,实时采集设备状态信息,并传输数据到诊断中心对设备运行状态进行分析的一项技术。它是远程技术服务/支持的一个重要组成部分,具有效率高、花费低、开放性、分布式、实时性等优点。新加坡南洋理工大学的 S. C. Hui 结合 CBR-ANN 技术作为 Web 服务端故障诊断引擎,开发了基于 Web 的智能远程故障诊断系统^[2];John A. Hossack 整合一个新系统到已有的数据采集与监视控制系统(SCADA)中,开发了更灵活且可伸缩的基于多 Agent 的远程故障诊断系统^[3,4];Liu Yun-

feng 使用基于 Lab Windows/CVI 平台和 Data socket 技术建立通用 Computer Supported Cooperate Work (CSCW) 环境,开发了基于虚拟仪表技术的远程故障诊断系统^[5]。

本文使用引力场方法对自组织特征映射(SOM)图进行区域划分,构造了自适应的故障诊断中心,无需人类专家,自动对远程设备的故障进行诊断。解决了设备状态信号中包含由复杂多变的设备工作环境导致的噪声信息、传感器自身产生的噪声信息的情况下模式的识别,具有很强的适应能力。自组织映射图(SOM)的基本原理源于大脑结构的特性,大脑中具有相同功能的脑细胞其聚集在一起。SOM 模拟这种特性,当网路学习完毕后,其输出处理单元相邻者会具有相似的功能。对 SOM 特征图进行邻域分析处理得到区域种子,以种子为引力源构建引力场,根据引力场中各点沿引力方向移动收敛到的种子区域为准则对区域进行划分。

基于上述特性本文使用 SOM 神经网络建立特征映射图

到稿日期:2008-10-15 本文受国家自然科学基金(60471055)和电子科技大学青年基金(JX7019)资助。

陈文字(1968—),男,博士生,副教授,CCF 高级会员,研究方向为模式识别、人工智能、编译技术、形式语言与自动机,E-mail: cwy@uestc.edu.cn;

刘井波(1976—),男,硕士生,讲师,研究方向为神经网络、人工智能、模式识别;程小鸥(1984—),女,硕士生,研究方向为形式语言、模式识别;

孙世新(1936—),男,教授,博导,研究方向为计算智能、模式识别。

以对模式进行聚类,并依据特征图建立引力场对聚类区域进行模式划分构建远程故障诊断系统。

(1)对检测数据进行平均值降噪处理、PCA降维等数据预处理。

(2)使用SOM神经网络进行模式特征聚类映射。

(3)在模式特征映射图上构建引力场并划分聚类区域,进行模式识别。

该方法很容易扩展到多维空间。文中对12种典型飞机起落架故障进行远程检测仿真,取得了比较满意的效果,较大地提高了正确识别率。

2 基本原理与方法

使用均值方法对检测数据进行处理以去除噪声信号,使用PCA分析对检测数据进行降维处理,使用SOM对输入模式进行聚类分析。

2.1 均值降噪

检测数据 $x(t)$ 由有效数据 $z(t)$ 和噪声信号 $g(t)$ 叠加而成,即:

$$x(t) = z(t) + g(t) \quad (1)$$

噪声信号由多个噪声源产生,并且每个噪声源都不起决定性的作用,故噪声信号满足正态分布,并可变为零均值。使用平均值法对数据降噪可增加诊断的正确率。

设 $E(g(t)) = 0$,则

$$E(x(t)) = E(z(t)) + E(g(t)) = E(z(t))$$

$$\text{有效数据 } z(t) = \frac{1}{k} \sum_{i=1}^k x(t-i) \quad (2)$$

2.2 PCA降维

主分量分析(Principal Component Analysis,简称PCA)在多维空间问题的研究中,由于变量维数较多,并且各维变量之间往往存在一定的相关性,通常导致检测数据包含有冗余信息。PCA是一个典型的统计学分析方法,找出数据中所谓的“主成份”。使用PCA方法可以在损失数据所包含的信息极少的情况下,对数据进行降维简化^[6],主要用于数据压缩和主特征提取。PCA主要有神经网络计算方法^[7]、特征值特征向量法计算。

向量组 x 的相关矩阵 xx^T 是一个对称矩阵,求相关矩阵的特征根并按降序排序: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m \geq 0$,求出每个特征根对应的特征向量: e_1, e_2, \dots, e_m ,令 $w = (e_1, e_2, \dots, e_m)$ 。设 y_i 为第 i 个主成份,则 $y_i = e_i^T x$ ($i=1, 2, \dots, m$)。选取前 m ($m < n$)个主成份, m 大小由给定的贡献率 g (一般 $g \geq 0.9$)决定。

贡献率定义为: $g = (\sum_{i=1}^m \lambda_i) / (\sum_{j=1}^n \lambda_j)$,主成份的矩阵表达式为:

$$y = w^T x \quad (3)$$

2.3 SOM自组织神经网络

自组织特征映射(SOM)网络是一个由全连接的神经元阵列组成的无教师自组织、自学习网络^[8]。思想为:处于空间中不同区域的神经元有不同的分工,当一个神经网络接受外界输入模式时,将会在神经元阵列上形成不同的反应区域,各区域对输入模式具有不同的响应特性。SOM构造了多维空间中点集到二维空间点集的映射^[9]。

SOM网络的学习过程:

(1)初始化。对输入神经元到输出神经元的连接权值 w_{ij}

(0)赋予较小的权值,对邻域函数 $S_j(0)$ 赋值;

(2)提供新的输入向量 X ;

(3)计算输入样本与每个输出神经元 j 之间的距离 d_j ,

$$d_j = \|X - W_j\| = \sqrt{\sum_{i=1}^N (x_i(t) - w_{ij}(t))^2} \quad (4)$$

找出神经元 k 使得对任意的 j 都有: $d_k = \min_j(d_j)$;

(4)给出随时间变化而变小的邻域函数 $S_k(t)$;

(5)调整权值,令

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)[x_i(t) - w_{ij}(t)] \quad (5)$$

其中 $\eta(t) = 1/t$ 或 $\eta(t) = 0.2(1-t/10000)$;

(6)计算输出 O_k ;

$$O_k = f(\min_j \|X - W_j\|) \quad (6)$$

其中 f 函数为0-1函数或其它非线性函数;

(7)如达到训练总数输出 O_k ,否则返回第(2)步。

3 基于引力场的模式聚类区域划分方法

机器设备使用环境情况的变化,不同批次的零件的使用导致设备的各种故障发生的概率发生相应的变化,因此要求故障诊断方法能适应这种情况。

在模式识别过程中,可以使用聚类、分类方法对输入模式进行模式识别。本文提出一种结合了聚类与分类方法的两步模式识别方法。首先对输入模式进行聚类分析,再对聚类结果进行模式区域划分。聚类方法在进行模式识别时具有如下特征:a)当待识别模式映射到一个区域的样本达到一定强度后可以认为构造了一个聚类。b)一个聚类中包含的样本数量越大,则它对周围其它的点属于该聚类的可能也越大。c)一个聚类所处区域度量越大说明该类的类间方差较大,它的邻域中的点属于该聚类的可能就越大。通过分析聚类中点及其邻域的关系并使用阈值找到各聚类可能的种子区域;故障出现的频率当作引力源的质量,使用引力场理论对聚类特征空间中的点进行引力场分析,根据特征空间中点沿该点引力方向移动所收敛到的种子区域来动态划分特征空间,把聚类区域划分成对应的模式区域进行模式识别。计算方法包括如下几个步骤。

(1)输入模式聚类分析。目前已使用的聚类算法有很多种,例如:动态聚类法、模糊聚类法、图论聚类法、神经网络聚类法等。本文使用SOM自组织特征图神经网络进行聚类分析。SOM将相似的向量映射到相邻的区域中,把输入空间中的向量映射到一个特征空间并形成聚类。聚类映射为: $x^a \rightarrow (i, j), q \in (1, 2, \dots, p)$ 表示输入空间中的向量 x^a 映射到聚类空间中的 (i, j) 点。

(2)聚类种子区域生成。聚类特征空间(SOM特征映射图)中点被模式映射的次数越多说明该点是聚类区域中心的可能越大,一个点的邻域中的点被映射的次数越多说明该点是区域的中心的可能越大。通过计算聚类特征空间(SOM特征映射图)中每一点的权值 ω_{ij} ,以较大的阈值 η 对其进行划分,确定种子区域,如图2所示。

$$\text{令: } f_{ij}^a = \begin{cases} 1 & x^a \rightarrow (i, j) \\ 0 & \text{other} \end{cases} \quad (7)$$

$$g_{ij}^a = \begin{cases} \xi & x^a \rightarrow (k, h) \cap (k, h) \in U((i, j), \sigma) \\ 0 & \text{other} \end{cases} \quad (8)$$

其中 $U((i, j), \delta)$ 表示 (i, j) 点的 σ 邻域中的点。 $\xi = d((k, h), (i, j))$,表示点 (k, h) 到点 (i, j) 的距离。则:

$$\omega_{i,j} = \beta_1 \sum f_{i,j}^n + \beta_2 \sum \frac{1}{g_{i,j}^n} \quad (9)$$

其中 β_1, β_2 为加权系数。令 A 表示区域中心矩阵, A 中元素 a_{ij} 取值如下:

$$a_{ij} = \begin{cases} 1 & \omega_{ij} \geq \eta \\ 0 & \omega_{ij} < \eta \end{cases} \quad i \text{ 为特征图中点的行数, } j \text{ 为列数。}$$

(3) 以种子区域为引力源生成动态引力场。根据训练时故障模式识别结果计算聚类映射点的频度, 计算邻域中各点的权值, 使用给定阈值选择种子区域, 以种子区域为引力源构造引力场, 使用引力场对聚类空间进行区域划分。在故障诊断过程中不断统计每种故障的出现次数作为相应种子区域的质量, 使引力场随各故障的频度变化而进行实时调整, 使 SOM 特征聚类空间的划分随故障发生频率而动态变化。

类似于万有引力, 聚类空间中各点的引力场的大小和方向等于每个种子区域对处于该点的单位质量的物体引力的矢量叠加。设种子区域分别为: S_1, S_2, \dots, S_n (n 为种子区域数), M_1, M_2, \dots, M_n 表示种子区域包含的样本数。 $\Omega_1, \Omega_2, \dots, \Omega_n$ 表示各种子区域的度量(长度、面积、体积)。聚类特征图中点 (i, j) 处单位质量受到全体种子区域的引力为 \vec{F}_{ij}^* 。设第 k 个种子区域对 (i, j) 点的单位质量点的引力为 \vec{F}_{ij}^k , $R = d_{SOM}$ 表示聚类特征映射空间的直径。令:

$$f_{ij}^k = \begin{cases} 0 & d((i, j), \Delta\Omega_k) \geq R \\ (1 - (\frac{d((i, j), \Delta\Omega_k)}{R})^{0.2})^5 & \text{other} \end{cases} \quad (10)$$

$$\vec{F}_{ij}^* = \sum_{\Delta\Omega_k \in \Omega_k} M_k \cdot (\frac{\Delta\Omega_k}{\Omega_k})^\theta \cdot f_{ij}^k \cdot \vec{e}((i, j), \Delta\Omega_k) \quad (11)$$

其中 $d((i, j), \Delta\Omega_k)$ 是 (i, j) 点到 Ω_k 的微元 $\Delta\Omega_k$ 的距离。

$\vec{e}((i, j), \Delta\Omega_k)$ 为以 (i, j) 为起点以 $\Delta\Omega_k$ 为终点的单位向量; $\theta \in (0, 1]$ 为类间方差的重要度, θ 越接近于 0 类间方差在分类中就越重要, 为 1 时不考虑类间方差。则单位质量在点 (i, j) 所受的总的引力为:

$$\vec{F}_{ij}^* = \sum_{k=1}^n \vec{F}_{ij}^k \quad (12)$$

(4) 引力场模式区域划分。让引力场空间中的点沿该点所受引力的方向移动, 直到收敛到一个种子区域为止。若点收敛到某个种子区域则说明该点属于收敛到的种子区域所在的类。以 (i, j) 为起点构造聚类空间中的曲线 L_{ij} , 该曲线上每一点的切线方向为该点引力场方向。若聚类空间中的点 (i, j) 沿直线 L_{ij} 收敛到某种子区域, 则该点与收敛到的种子区域具有相同的类。令 $\lim_{L_{ij}}(i, j)$ 表示为点 (i, j) 沿直线 L_{ij} 收敛的极限。

$$(i, j) \in S_k \Leftrightarrow (\lim_{L_{ij}}(i, j) = (u, v)) \cap (d((u, v), S_k) = \min(d((u, v), S_z))) \quad (13)$$

$$z = 1, 2, \dots, n$$

4 SOM 神经网络、同步区域生长法实现飞机起落架刹车系统远程故障诊断

经实验发现, 用平均值法可以很好地去除高斯噪声; 用 PCA 主成分分析方法可以在损失信息很少的情况下降低模式向量的维数; SOM 自组织特征映射神经网络可以把模式向量在特征空图中进行特征聚类, 使相近的模式位置也相近; 引力场区域划分方法可以很好地处理分布致密聚类与分布非致密聚类、聚类间方差变化大的多聚类识别问题。

综合以上方法构造了一个远程故障诊断系统模型(如图 1 所示), 模型包含如下几个主要部分:

(1) 硬件部分。包括传感器、多路设备、发射机、接收机、分路设备。

(2) 数据预处理部分。包括检测数据降噪; 使用特征值、特征向量法对降噪数据进行 PCA 主成份分析。

(3) 神经网络自组织映射。对 PCA 分析后的数据构造 SOM 进行自组织映射, 进行聚类分析。

(4) 引力场聚类区域划分。计算聚类映射模式的频度, 并使用邻域分析, 使用给定阈值选择种子区域并构造引力场对聚类空间进行区域划分。在诊断过程中引力场以各种种子区域中故障模式的数量为质量动态调整引力场。

(5) 模式识别。因 SOM 为自组织神经网络故应考虑同步区域生长后的稀疏矩阵的区域是否与待识别模式数相同, 每个区域是否只有唯一的典型模式出现。典型模式与其仿真映射间构成一一映射关系 $y: I_k \leftrightarrow Map_j$, I_k 为 k 种典型故障模式输入, Map_j ($j = 1, 2, \dots, k$) 分别为系统的 k 种输出, 如果仿真模式经本系统处理后和哪个典型故障模式落入同一个区域则识别为该模式。




图1 远程故障诊断系统模型

5 试验

使用本系统对某型飞机的起落架刹车系统的典型故障样本(如表 1 所列)进行训练和测试。

表1 起落架刹车故障典型样本

	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9
y_1	0.0	0.0	0.3	0.2	0.3	0.5	0.0	0.3	0.5
y_2	0.7	0.5	0.0	0.3	0.1	0.7	0.8	0.1	0.2
y_3	0.2	0.4	0.3	0.1	0.1	0.1	0.4	0.1	0.1
y_4	0.2	0.2	0.4	0.2	0.2	0.2	0.2	0.2	0.2
y_5	0.0	0.3	0.5	0.2	0.2	0.4	0.2	0.2	0.2
y_6	0.3	0.1	0.2	0.1	0.0	0.3	0.5	0.1	0.3
y_7	0.1	0.1	0.0	0.2	0.3	0.1	0.2	0.3	0.1
y_8	0.2	0.2	0.2	0.0	0.2	0.6	0.2	0.1	0.3
y_9	0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.1	0.2
y_{10}	0.0	0.1	0.3	0.0	0.0	0.3	0.1	0.0	0.3
y_{11}	0.0	0.1	0.3	0.2	0.1	0.3	0.1	0.0	0.3
y_{12}	0.2	0.3	0.1	0.2	0.3	0.1	0.2	0.2	0.2

(X 为征兆集 x_i ; $i = 1, 2, \dots, 9$, Y 为故障集 y_j ; $j = 1, 2, \dots, 12$)。

在 12 种典型故障数据中分别加入方差为 0.05, 0.08, 0.12, 0.2, 0.3, 0.4, 0.5 的噪声信号, 每组测试信号矩阵为 9 行 1200 列, 每种故障有 100 个测试数据; 平均值降噪参数 $k = 10$; PCA 贡献率 $g = 0.99$, 邻域分析采用为 3×3 邻域; $\theta = 0.4$; 种子区域包含的点不超过分类区域中点的 9%; SOM 训练学习 200 步, 适应函数: trains, 初始化函数: initlay, 训练函数: trainr。引力场生成过程中 SOM 映射特征聚类图中种子区域及典型故障模式如图 2 所示, 种子区域及以它们为引力源产生的引力场如图 3 所示, 由生成的引力场进行的聚类区域划分如图 4 所示。SOM 神经网络输入层维数 9, 分别取 15

×15, 20×20, 25×25 的神经元阵列为特征映射聚类图并使用引力场聚类模式区域划分, 并进行模式识别; 20×20 的使用到典型故障模式的最小欧氏距离 (Euclidean Distance) 划分聚类区域的故障模式识别进行对比, 如图 5 所示。两种方法分别计算 20 次计算正确识别率的平均值, 识别率如图 6 所示, 其中横坐标为噪声方差, 纵坐标为故障正确识别率。




图 2 种子区域及典型故障模式分布图




图 4 引力场模式区域划分图 图 5 最小欧氏距离模式区域划分

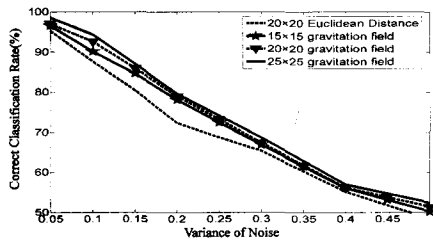


图 6 分类正确率对比图

实验结果表明:

- (1) 增加 SOM 竞争层神经元阵列大小能使系统的故障识别率增加。
- (2) 引力场区域模式划分方法与种子区域大小、种子区域的空间分布位置相关。
- (3) 引力场模式聚类区域划分方法考虑了故障模式的类

内、类间方差对模式区域划分的影响, 且区域划分边界点极少。比欧氏最小距离模式分类方法的故障模式正确识别率高, 且低噪声情况下的故障模式正确率比高噪声情况下提高大。

(4) 本系统是自学习的, 其活化过程是单向的前馈方式, 而非多遍反馈, 可以并行处理, 能够快速识别故障。

结束语 本文建立了远程故障检测系统模型, 使用某型飞机起落架刹车系统典型故障数据进行实例诊断。模型使用均值降噪、PCA 降维, SOM 神经网络发挥其联想记忆和并行处理功能, 将输入网络的数据进行特征映射聚类, 对特征映射聚类图使用引力场区域划分法进行模式区域划分并进行模式分类, 较好地实现了远程故障的在线检测, 计算结果符合实际情况; 同时也表明基于 SOM 特征映射图的引力场划分方法是很有潜力的远程模式识别方法。

参考文献

- [1] Fong A C M, Hui S C. An intelligent online machine fault diagnosis system [J]. Computing & Control Engineering Journal, 2007, 10: 217-223
- [2] Hui S C, Fong A C M, Jha G. A web-based intelligent Fault Diagnosis system for customer service support. Enginee Ring Applications of Artificial Intelligence, 2001, 14: 537-548
- [3] Marzi R, John P. Supporting Fault Diagnosis through a multi-agent-architecture. Mathematics and computers in simulation, 2002, 60: 217-224
- [4] Hossack J A, Menal J, McArthur S D J, et al. A Multi. Agent Architecture for Protection Engineering Diagnostic Assistance. IEEE Transactions on Power Systems, 2003, 18(2)
- [5] Liu Yun-feng, Miao dong, Peng Yun-hui, et al. Remote fault diagnosis based on virtual instrument technology // Proceedings 2006 10th International Conference on Computer Supported Cooperative Work in Design. 2006: 969-973
- [6] Oja E. A simplified neuron model as a principal component analyzer. J. Math. Biol, 1982, 15: 267-273
- [7] 章毅, 王平安, 周明天. 用神经网络计算矩阵特征值与特征向量 [J]. 计算机学报, 2000, 23(1): 71-76
- [8] Kohonen T. The Self-Organizing Map // Proceedings of IEEE. 1990, 78(9): 1464-1481
- [9] 李伟, 钟飞, 何涛, 等. 基于无监督神经网络的故障模式识别 [J]. 计算机测量与控制, 2006, 14(6): 742-744
- [10] Gonzalez, Woods R. Digital Image Processing. Addison Wesley, Reading MA, 1992

(上接第 263 页)

步骤, 本文在彩色图像基础上采用多尺度的区域生长方法进行图像分割, 充分利用了丰富的颜色信息和图像的空间信息。多尺度的运用可以很好地避免车牌目标的漏检, 使得车牌检测准确率高, 对分割区域形状的控制使得提取的车牌区域规范、整齐, 有利于后续的字符识别。实验表明基于区域分割的车牌检测对于倾斜的或侧面车牌图像, 也有较好的检测效果。

参考文献

- [1] Shapiro V, Gluhchev G, Dimov D. Towards a Multinational Car License Plate Recognition System [J]. Machine Vision and Applications, 2006, 17(3): 173-183
- [2] 吴舟舟, 李树广. 基于分级边缘间距的实时车牌检测 [J]. 中国图象图形学报, 2007, 12(2): 315-321
- [3] 曾丽华, 李超, 熊璋. 基于边缘与颜色信息的车牌精确定位算法

[J]. 北京航空航天大学学报, 2007, 33(9): 1112-1116

- [4] Jia X H W, Zhang H, Piccardi M. Mean Shift for Accurate License Plate Localization [A] // Proceedings of the IEEE Conference on Intelligent Transportation Systems [C]. Vienna, Austria. 2005: 566-571
- [5] 李刚, 曾锐利, 林凌, 等. 基于数学形态学的车牌定位算法 [J]. 仪器仪表学报, 2007, 28 (7): 1323-1327
- [6] Matas J, Zimmermann K. Unconstrained License Plate and Text Localization and Recognition [A] // Proceedings of the IEEE Conference on Intelligent Transportation Systems [C]. Vienna, Austria. 2005: 572-577
- [7] Baatz M, Shpe A. Multiresolution Segmentation, An Optimization Approach for High Quality Multi-scale Image Segmentation [A] // Strobl, Blaschke & Greisebener, eds. Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT-Symposium Salzburg 1999 [C]. Karlsruhe, Herbert Wichmann Verlag, 2000: 12-23