普通高等教育精品规划教材

面向21世纪课程教材

高等学校信息管理学专业核心课教材

第二版

信息检索

焦玉英 符绍宏 何绍华 编著

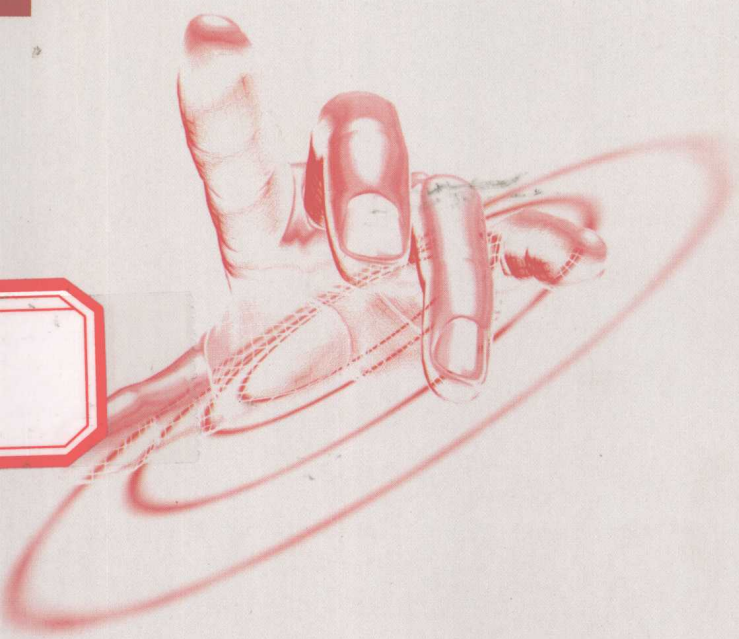

INFORMATION MANAGEMENT SCIENCE

WUHAN UNIVERSITY PRESS
武汉大学出版社

普通高等教育精品规划教材

面向21世纪课程教材

高等学校信息管理学专业核心课教材

第二版

信息检索

焦玉英 符绍宏 何绍华 编著

INFORMATION MANAGEMENT SCIENCE

WUHAN UNIVERSITY PRESS
武汉大学出版社

图书在版编目(CIP)数据

信息检索/焦玉英,符绍宏,何绍华编著. —2 版. —武汉:武汉大学出版社,2008.7

普通高等教育精品规划教材

面向 21 世纪课程教材

高等学校信息管理学专业核心课教材

ISBN 978-7-307-06396-9

Ⅰ.信… Ⅱ.①焦… ②符… ③何… Ⅲ.情报检索—高等学校—教材 Ⅳ.F252.7

中国版本图书馆 CIP 数据核字(2008)第 093160 号

责任编辑:严 红 郭 静 李梦娟 责任校对:王 建 版式设计:詹锦玲

出版发行:**武汉大学出版社** (430072 武昌 珞珈山)

(电子邮件:wdp4@whu.edu.cn 网址:www.wdp.whu.edu.cn)

印刷:湖北省通山县九宫印务有限公司

开本:720×1000 1/16 印张:25 字数:430 千字 插页:1

版次:2001 年 5 月第 1 版 2008 年 7 月第 2 版

2008 年 7 月第 2 版第 1 次印刷

ISBN 978-7-307-06396-9/G·1208 定价:34.00 元

内容简介

本教材内容包括信息检索与网络知识、信息查询的基础理论、方法、技术与检索策略、检索服务；国内外各类型文献信息检索工具的概述、检索体例剖析、检索实例展示、检索技巧；计算机、光盘、联机检索技术介绍；网络信息资源组织基本原理、主要查询工具、查询方法及发展与研究趋势；检索咨询服务与评价等。

本书主要面向国内高等院校信息管理类及其相关专业的本科生，同样也适合图书馆参考咨询人员，信息中心服务人员，企、事业信息管理人员参考。

再版前言

信息检索作为一个学科的历史可以追溯到20世纪中期，其有代表性者如Granfield所确立的标引语言及检索系统评价方案，Salton提出的矢量空间模型与文献聚类技术，Roberson及Van Rijisbergen、Sparck Jones等人研制的概率模型，Smeaton在计算机语言学基础上的检索技术开发等的研究与试验，他们都对直至20世纪80年代末期文献检索领域的研究对象、原则和方法产生过重要影响。尽管其研究成果和设计思想基本上是在一个模拟文献检索作出的人工或虚拟环境中进行的，甚至还带有某种程度上的假说性，但却奠定了文献检索这门课程基于以“提问—检索”模式为核心的相关理论与方法的基础，传统的赋值标引，规范化的检索语言，线性的书目数据库结构，预定的检索策略，以回答检索提问为主的服务方式等构成了该模式的主要概念体系、方法和原则。

20世纪90年代以来，以Internet为核心连接起来的全球计算机网络使传统的以相对集中和规范为基准的文献数据库及其检索系统面临严峻的挑战。主要表现在：信息资源内容之广泛涉及各个学科领域乃至人类生活的方方面面；信息类型以动态、静态、音频及超声频等多姿多彩的方式再现；各类型、多种品牌的网络信息查询工具如雨后春笋般不断涌现；网络化与数字化技术将分布在世界各地主机上的信息资源数据库联为一体，为人们跨越时空、行业、地域快速、高效传递信息提供了国际化的知识信息平台，极大地提高了用户获取信息的主动性、自主性。传统的以文献为主要检索对象的“提问—检索”模式已逐步被网络环境中“浏览—查询”模式取代。其最大特点是知识载体的多样性、复杂性；信息存储的动态性；查询工具与方法的智能化；搜索过程与结果的可视化；用户利用信息的高度个性化与主动性等。这些变化与特点不断丰富着信息检索的理论与方法内容。

本次修订的宗旨是在保留传统信息检索的基本理论与方法体系的基础上，尽可能反映网络环境下信息检索的理论与工具、方法，尤其是国内外各类型专门检索工具的变化与检索示例。

本书共12章，由武汉大学信息管理学院焦玉英、何绍华，北京师范大学信息技术与管理学系符绍宏共同完成。具体分工如下：第1、2、3、6、7、8、12章由焦玉英修编；第5、10、11章由符绍宏修编；第4、9章由何绍华修编。

袁静、雷雪、方清华等博士在本次再版修订中付出了辛勤劳动。本书的再版修订同时得到武汉大学出版社严红编审的大力支持和郭静编辑的鼎力帮助，在此一并感谢。

焦玉英

2008年3月

目　录

1 信息检索概述

1.1 信息的概念与特征

信息的概念十分广泛，围绕信息而出现的信息资源、信息技术、信息系统、信息产业、信息化社会和社会信息化等相关术语不胜枚举。可见，信息的观点、概念和方法已经被政治、经济、科技、文化、生产等各个领域所接受和应用。那么，究竟什么是信息？至今仍无确切、统一的定义，站在不同的角度就有不同的理解或解释。

从自然界角度看，客观事物的普遍属性通常可用它的运动性、时空性、能量、反映性、质料、系统性等表示。其普遍性既是事物千差万别的表现，又是事物之间相互联系的内容。信息概念的引入旨在表明，信息既不是物质，也不是能量，而是依附于自然界客观事物而存在，也就是说，只要有物质存在，就有表征其属性的信息。例如，地球昼夜的变化是一种信息，它反映了地球绕太阳自转的运动特性和状态；山的高度是一种信息，它反映出山的空间特性；树干的年轮是一种信息，它反映了树木成长的时间特性——树龄；闪电是一种信息，它反映了云层中所含能量的特性；花的香味也是一种信息，它反映了花分子结构的化学特性等。因此，可以认为，信息的概念，实际上就是客观事物运动状态、时空特性、能量大小、质料、系统特征、相互联系方式等一切反映事物客观属性的总称。从这种意义上看，信息比客观事物的属性更具一般性与普遍性。

从人的主观认识角度看，信息是储存在人脑中的思想、观念、知识等形态。它既是每个具体人这一特殊事物属性的一种表征，又是外部客观事物属性在人脑中留下的印记，是物质反映属性的高级形式。哲学家把人的这些直

接接受客观事物信息的功能称为人的自然信息功能。人在自然界的活动即是不断排除信息传输过程中的噪声与干扰，选择、过滤和提取正确信息的过程，或者说，通过感觉、知觉等阶段对来自不同方位的信息进行综合，如将光、电、声、场、分子等各种介质的信息形态进行转换、传递，编码为大脑可以识别、存储的形式，并且不断借助各种信息技术来弥补人自身的自然信息功能缺陷等。

从技术角度看，信息的概念体现在一切人造工程、设备的技术和有关技术的特性之中。信息既是这些人造客观事物的表征，也是人的知识、文化及艺术水平等属性的反映。

从人工文化角度看，信息概念的实质在于它以某种编码形式储存或传输于某种介质之中，如存储在书本、纸张上的文字信息，记录在唱片、录音带上的声音信息，印制在画报、照片、录像带上的图像（形）信息，计算机系统中的各种数字、数据信息等。我们把存储在这些物理介质中的信息统称为文献信息。文献既是记录信息的物质载体，又是人类的精神文化产品。

图 1-1 标示出了客观信息与主观信息的相互关系。

图 1-1 中，人从主观上认识世界以及与客观现实世界的信息交流活动是一种自人类社会产生以来在其整个历史过程中不断反复、发展的过程。这一过程不仅反映了人类认识客观世界，逐渐逼近真理的过程，同时也推进着社会的信息化进程。

信息有如下的特征：

（1）客观性与普遍性

信息既不是物质，也不是能量，是客观事物普遍性的表征，信息是无处不在，无时不有的普遍社会现象。

（2）流动性与传递性

信息在事物之间的相互联系必定在信息的流动中发生。信息的传递性表现在人与人之间的消息交换，人与自动机、自动机与自动机之间的信息交换，动物界和植物界的信号交换，同时，人类进化过程中的细胞选择、遗传也被看做是信息的传递与交换。

（3）多样性与综合性

信息在不同的领域具有多种不同的特性或表现形式，如客观事物中的各种自然属性；人工设备的技术特征；人类社会的各种社会特征；人脑中反映客观事物认识的思想、知识；人类交流信息过程中的声音、文字、图像以及

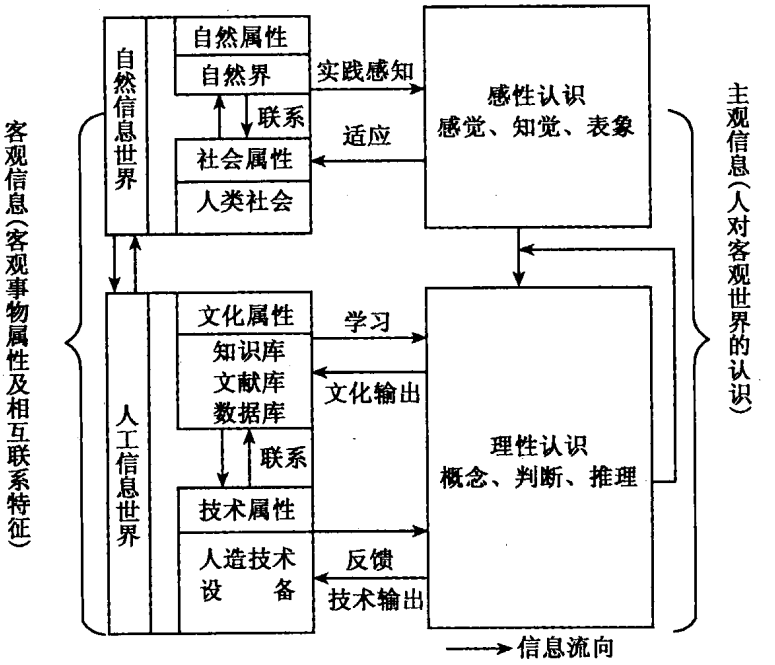

图 1-1 客观信息与主观信息的相互关系

用各种编码形式记录下来的数据、新闻、情报、消息等。各种形式的信息又常常以综合的方式表现事物的特征，所谓“多媒体”正是信息多样性和综合性的集中表现。

(4) 相对性与有效性

从信息作为事物相互联系的反映角度看，信息源不确定的程度或者信息源接受信息量的多少，均与信宿的状态有关。这一特征在人作为信宿接受信息的过程中表现得尤为明显。同一信息对具有不同认知水平的人所产生的作用和有效性也不相同。

(5) 积累性与价值性

信息通过人脑思维或人工技术设备的综合、加工和处理，不断积累丰富，提高其质量和利用价值。信息的质量和价值，实际上是对客观事物属性反映的深度和真实程度的认识。虽然信息是人类的一种重要资源，但信息只有被利用才会产生价值，否则，其价值或随时间的流逝而减少，或成为“信息垃圾”。

1.2 信息的类型与存储载体

1.2.1 信息的类型

信息与和人类智能活动有关的知识、技术、科学、文化、社会等密切联系在一起，其涉及范围如此之广，以至于很难用统一的标准进行分类。

1.2.1.1 按信息表现形式划分

(1) 文字信息

文字是人们为了实现信息交流、通信联系所创造的一种约定的形象符号。广义的文字还包括各种编码，如 ASCII 码、汉字双字节代码、国际电报与单元代码以及计算机中的二进制数字编码等都是一些符号的约定。这些文字、符号、代码均是信息的表述形式，其内容再现于它们的结构属性之中。如基本笔画的不同组合，字和字母的不同组合，二进制码“0”和“1”的不同排列等，分别代表不同的信息内容。

(2) 图像信息

图像（形）是一种视角信息，它比文本信息直接，易于理解。人工创造的图像（形），如一张纸、一幅画、一部电影，大自然的客观景象等都是抽象或间接的图像信息。随着多媒体技术的发展，各类图像信息库将会极大地丰富人类生活。

(3) 数值数据信息

数值数据是“信息的数字形式”或“数字化的信息形式”。狭义的“数据”是指有一定数值特性的信息，如统计数据、气象数据、测量数据以及计算机中区别于程序的计算数据。广义的数据是指在计算机网络中存储、处理、传输的二进制数字符编码，文字信息、图像信息、语言信息以及从自然界直接采集的各种自然信息等均可转换为二进制数码，网络中的数据通信、数据处理和数据库等就是广义的数值数据信息。

(4) 语音信息

人讲话实际上是大脑的某种编码形式的信息转换成的语言信息的输出，是一种最普遍的信息表现形式。音乐也是一种信息形式，是一种特殊的声音信息，它通过演奏的方式表达丰富多彩的信息内容。

1.2.1.2 按信息的出版类型划分

(1) 图书

包括专著、教科书、各种科普读物及各专业参考工具书等。图书经编著

者精心选择，反复斟酌后写成，其内容系统、成熟、定型，信息经筛选，可靠性强，是人们从事学习、研究不可缺少的信息来源。不过，传统印刷业图书出版周期较长，体积大，更新速度慢，电子版图书的出现将弥补这一缺陷。

（2）期刊

指按同一专业领域定期或不定期出版的连续性出版物。它出版数量大、周期短、内容新颖，能迅速反映国内外的各种学科专业的水平和动向，是人们获取一般基础理论研究知识的重要信息源。期刊按内容划分，有综合性的与专业性的；按性质划分，有学术性的、技术性的、消息性的、检索性的以及通报性的；按对原文压缩程度划分，有目录、索引、文献、快报、速评、文献指南、书目之书目等。

（3）政府出版物

指各国各级政府部门及所属机构出版的文献信息资料，它主要包括社会科学与自然科学两大类。其中行政文件，如讨论会记录、各种法令、外交文件、统计数据占大多数，科技资料数量相对较少。

（4）科技报告

指各学术团体、科研机构、大学研究所的研究报告及其研究过程中的记录。科技报告理论性强，是了解某一领域科研进展状况、发展动态的重要情报源。但科技报告保密性强，难以获取。

（5）专利文献

指发明人向政府部门（专利局）递交的、说明自己的创造的技术文件，同时也是实现发明所有权的法律性文件。专利文献包括专利说明书、专利公报（摘要）、商标、设计公报以及检索专利的工具等。专利文献具有技术性、新颖性、独创性、实用性等特征，是重要的技术经济情报来源。

（6）会议文献

指在国内外学术团体举行的专业会议上发表的论文与报告。与期刊相比，会议文献具有传播情报信息更迅速的功能。它反映了某学科、专业的最新成果和发展水平动向，是科研工作不可缺少的情报源。

会议文献一般分为会前、会中和会后三种形式。会前资料如会议通知、会议程序单、论文摘要等；会中资料如开幕词与闭幕词、会议决议书等；会后资料如会议结束后经整理出版的专门会议丛刊、会议论文集等。

（7）学位论文

指高等院校研究生（硕士或博士）攻读学位而撰写的毕业论文。它经专家评审、鉴定通过，一般来说具有学术性强的特点，往往有独到的见解。

（8）技术标准和规范

这主要指包括技术规范、技术标准、操作规程、建议、准则、术语、专门名词等在内的各种技术文件。在标准实践领域里，技术标准和规范在适用范围方面是有区别的。前者是一种得到管理机构认可，适用于一定专业领域的技术规范，具有法定性；后者是指对产品、材料、工艺流程或技术特点的说明书，它仅以满足买方或工业规定的要求为准则。

技术标准主要包括尺寸标准、材料标准、性能标准、方法标准、操作规程、术语和图形符号标准、文献标准等。

（9）产品样本说明书

它是制造厂家和产品销售者介绍其产品的宣传性出版物。它介绍的是已投产和行销的产品。通过产品样本说明书可以了解厂家的工艺水平、管理水平和产品发展趋势方面的情报。由于产品样本说明书附大量图表、产品特性曲线、方程等，因此具有直观的特点。同时，厂家为了推销产品，往往免费赠送，使产品样本说明书具有易于获取的优点。

产品样本说明书除直接出版发行之外，还常常被包含在一些贸易刊物、企业介绍、数据手册之中。

（10）技术档案

它是在科技生产活动中形成的一系列以工程技术图纸、任务书、协议、合同、设计方案以及与此有关的调查统计数据等材料组成的文件。技术档案具有技术性、适用性、保密性等特征。

1.2.1.3 *按信息的加工程度划分*

（1）一次信息

一次信息是人们研究或创造性活动成果的直接记录，一般指公开出版的图书、期刊论文、科技报告、会议文献、学位论文、发明专利等。不管其信息存储于何种物质载体及出版的版次，只要是原始资料就是一次信息。一次信息零碎、分散、无序，有的很难获取。

（2）二次信息

二次信息是对一次信息进行加工、整理而成的。如目录、文献、索引等各种书目数据库是二次信息的核心。二次信息的形成是信息从分散、无序到集中、有序的书目控制过程。

（3）三次信息

三次信息是对一、二次信息进行综合、分析等深加工的产物。如评论、进展报告、述评、百科全书、年鉴、指南、期刊书目等。

1.2.2 信息的存储载体

1.2.2.1 印刷型

它是以手写和印刷技术为手段，以纸张记录信息的载体形式。它的优点是可以直接阅读，携带方便，因此成为人类科研、生产、学习、文化交流等活动中最常用的工具。与现代信息载体相比，印刷型信息载体存储信息密度小，占用收藏空间大，难以长期保存。

1.2.2.2 缩微型

缩微型主要指以感光材料记录文字及其相关信息的载体。常见的有缩微胶卷和缩微胶片。缩微型信息载体的优点是便于保存、转移和传递，缩小文献的体积，可节约书库面积达95%以上，而其成本却只是印刷型的1/10左右，但缩微型信息载体必须借助阅读机或阅读复印机才能使用。世界上许多大型文献信息中心都将学位论文、科技报告等文献制作成缩微品加以收藏和保存。

缩微型信息载体借助电子技术、计算机技术进一步增强了自身的功效。例如，它可以制作成计算机存取载体的输入胶片（Computer Input Microfilm—CIM）和输出胶片（Computer Output Microfilm—COM）。

1.2.2.3 声像型

它指记录声音、图像信号的信息载体，如录音带、录像带、幻灯片、影视片以及近年来推出的高密度视听光盘。声像型信息载体可以让人们通过自己的视觉、听觉感受到直观、形象、生动、逼真、丰富多彩的信息世界。

1.2.2.4 电子型

它是指采用电子手段并以电子形式存在，利用计算机及现代通讯方式提供信息的一种新兴载体。它的前身是机读型。

电子型出版物内容丰富，类型多。按信息存储介质划分，主要有软磁盘与光盘两大类；按出版物类型划分，主要有电子期刊、电子图书、电子报纸、电子名录、电子地图、各种联机信息库和光盘数据库产品或磁带、软盘等产品；按媒体的信息结构组织形式划分，主要有以线性顺序组织知识单元的文本型出版物和以节点和链路组织知识的超文本出版物，以及融文本、图像、声音信息于一体的多媒体出版物，综合超文本与多媒体技术特点产生的超媒体出版物等。

电子出版物的问世是信息时代的重要标志，它改变了书刊的物理形态，开辟了一种新的信息分发渠道，极大地提高了信息的传递速度，加速了社会信息化的进程。与其他传统出版物相比，电子出版物的优点是：

① 信息容量大，一张普通光盘的信息存储量可达600M；《人民日报》网络版数据库中存有约15G的数据，相当于75亿个汉字的信息量。

② 出版周期短，易更新，它不需要制版、印刷、装订等环节，并可利用电子手段随时对内容进行增、删、改。

③方便检索，凡在数据库中存储的数据，只要点一下鼠标即可随意浏览或检索所需信息。

④易复制，可将网上数据拷贝到机器的硬盘或软盘上，也可以打印成纸质文件。

⑤ 可交互性，任何人都可以在网上发表见解，互相交流信息。

⑥ 低成本、高效益、非实物、非独占、无损消费、可共享等。

1.2.2.5 网络型

它是指存储在互联网上的信息，通过网络提供和获取信息的一种形式。这种类型的信息包罗万象，分布广泛，内容丰富多样，所载信息量可以突破页码的限制而扩大，其优点是：①不受时间限制，信息获取快，传播快，更新快，时效性强；②多媒体合成，表现生动，图文声像并茂；③传播形式的非线性和交互性。但其缺点也很明显：内容庞杂，类型多样，良莠不齐，易变不稳定，组织无序、分散。因此，“信息过载”和“资源迷向”在所难免，给用户进行快速的检索和获取信息带来一定困难。

1.3 信息的现代传输方式

信息是客观事物属性和相互联系的表征，而不是物质。因此，信息的传输必须借助于物质和能量的作用。传输媒体正体现了这种信息及能量的相互关系。人工信息传输系统，如通信系统恰好为信息的传输提供了媒体和控制媒体参数的方法，使人们能够通过各种通信系统获得数千里之遥传来的信息。在当代，信息传输正是通过计算机网络在综合现代先进信息技术基础上实现的。

1.3.1 计算机网络信息传输的基本结构及通用模型

任何网络都是传输网络，任何网络系统也都是传输、交换信息的系统。

网络的重要特征之一就是联网的所有用户（计算机）之间都能互相建立连接和进行相互通信。因此，从网络角度看，任何一个网络系统（无论是通信系统或计算机网络），不管它的内部结构如何，都应该把它们看成一个具有交换功能的信息传输系统，一个具有许多分布的交换节点组成的网络