


第 5 章



神经网络

本章介绍神经网络的基础知识和原理。从感知机开始,逐步介绍全连接神经网络、BP 神经网络以及正则化技术。神经网络是一种模拟生物神经系统工作原理的机器学习模型,在图像分类、语音识别等领域有重要应用。感知机是最简单的神经网络模型,用于解决二分类问题。随后,将深入研究全连接神经网络,它是深度学习中的基础模型,在不同任务中广泛应用。接着介绍 BP 神经网络,它使用梯度下降法进行训练,具有较强的学习能力。最后介绍正则化技术,包括 Dropout 正则化和批标准化,用于防止过拟合和提高模型的鲁棒性。通过学习本章内容,读者将对神经网络的基础概念、感知机、全连接神经网络、BP 神经网络及正则化技术有更深入的理解,并能够应用于解决实际问题。

5.1 神经网络简介



5.1.1 神经网络理论

神经网络,是一种应用类似于大脑神经突触连接结构进行信息处理的数学模型,如图 5-1 所示。它是在人类对自身大脑组织结合和思维机制的认识理解基础之上模拟出来的,是根植于神经科学、数学、思维科学、人工智能、统计学、物理学、计算机科学及工程科学的一门技术。




图 5-1 人体大脑神经突触连接结构

人工神经网络(Artificial Neural Network, ANN)简称为神经网络(NN),是基于生物学

中神经网络的基本原理,在理解了人脑结构和外界刺激响应机制后,以网络拓扑知识为理论基础,模拟人脑的神经系统对复杂信息的处理机制的一种数学模型。该模型以并行分布的处理能力、高容错性、智能化和自学习等能力为特征,将信息的加工和存储结合在一起,以其独特的知识表示方式和智能化的自适应学习能力,引起各学科领域的关注。它实际上是一个由大量简单元件相互连接而成的复杂网络,具有高度的非线性,能够进行复杂的逻辑操作和非线性关系实现的系统。

神经网络是一种运算模型,由大量的节点(或称神经元)相互连接构成,如图 5-2 所示。每个节点代表一种特定的输出函数,称为激活函数。每两个节点间的连接强度称为权重,权重的大小代表可能性大小,神经网络就是通过这种方式来模拟人类的记忆。网络的输出则取决于网络的结构、网络的连接方式、权重和激活函数。而网络自身通常都是对自然界某种算法或者函数的逼近,也可能是对一种逻辑策略的表达。神经网络的构筑理念是受到生物的神经网络运作启发而产生的。人工神经网络则是把对生物神经网络的认识与数学统计模型相结合,借助数学统计工具来实现的。另外,在人工智能学中的人工感知领域,我们通过数学统计学的方法,使神经网络能够具备类似于人的决定能力和简单的判断能力,这种方法是对传统逻辑学演算的进一步延伸。




图 5-2 神经网络的连接方式

在人工神经网络中,神经元处理单元可表示不同的对象,如特征、字母、概念,或者一些有意义的抽象模式。网络中处理单元的类型分为三类:输入单元、输出单元和隐藏单元。输入单元接收外部世界的信号与数据,输出单元实现系统处理结果的输出,隐藏单元是处在输入和输出单元之间,不能由系统外部观察的单元。神经元之间的连接权值反映了单元间的连接强度,信息的表示和处理体现在网络处理单元的连接关系中。人工神经网络是一种非程序化、适应性、大脑风格的信息处理,其本质是通过网络的变换和动力学行为得到一种并行分布式的信息处理功能,并在不同程度和层次上模仿人脑神经网络的信息处理功能。

5.1.2 发展历史及现状

1943 年,美国数学家 W. 皮茨(W. Pitts)和心理学家 W. 麦卡洛克(W. McCulloch)首次提出了人工神经网络这一概念,并使用数学模型对人工神经网络中的神经元进行了理论建

模,开启了人们对人工神经网络的研究。

1949年,著名心理学家 D. 赫布(D. Hebb)给出了神经元的数学模型,提出了人工神经网络的学习规则。

1957年,著名人工智能专家 F. 罗森布拉特(F. Rosenblatt)提出了感知机(Perceptron)人工神经网络模型,并提出采用 Hebb 学习规则或最小二乘法来训练感知机的参数,感知机是最早且结构最简单的人工神经网络模型。随后,F. 罗森布拉特又在康奈尔大学航空实验室通过硬件实现了第一个感知机模型 Mark I,开辟了人工神经网络的计算机向硬件化发展的方向。感知机是一种前向人工神经网络,采用阈值型激活函数,只含一层神经元。通过训练网络权值,对于一组输入响应,感知机可以得到 1 或 0 的目标输出,从而实现分类输入响应的目标。但感知机的分类能力非常有限,只能够处理简单的二元线性分类,受限于其只具有一层神经网络,它不能处理线性不可分问题,如异或问题。

1980年,基于传统的感知机结构,深度学习创始人,加拿大多伦多大学教授 G. 辛顿(G. Hinton)采用多个隐藏层的深度结构来代替感知机的单层结构,多层感知机(Multi-Layer Perceptron)模型是其中最具代表性的,而且多层感知机也是最早的深度学习网络模型。

1974年,保罗·韦伯斯(Paul Werbos)提出采用反向传播法来训练一般的人工神经网络。随后,该算法进一步被 G. 辛顿、杨立昆(Y. LeCun)等人应用于训练具有深度结构的神经网络。反向传播法根据神经网络输出层的计算误差来调整网络的权值,直到计算误差收敛为止。但是,反向传播法训练具有多隐藏层的深度网络的网络参数的学习性能并不好,因为具有多隐藏层的深度网络的网络参数的训练问题是一个非凸问题,基于梯度下降的反向传播法很容易在训练网络参数时收敛于局部极小值。此外,反向传播法训练网络参数还存在很多实际问题,如需要大量的标签样本来训练网络的权值,多隐藏层的神经网络权值的训练速度很慢,权值的修正随着反向传播层数的增加逐渐削弱等。

面对采用反向传播法来训练具有多隐藏层的深度网络的网络参数时存在的缺陷,一部分研究人员开始探索通过改变感知机的结构来改善网络学习的性能,由此产生了很多著名的单隐藏层的浅层学习模型,如 SVM、Logistic Regression、Maximum Entropy Model 和朴素贝叶斯模型等。浅层学习模型能够有效地解决简单或者具有复杂条件限制的问题,但受限于只含一个隐藏层,所以浅层学习模型特征构造的能力有限,不能有效地处理包含复杂特征的问题。为了同时解决具有多隐藏层的深度网络在参数训练时存在的缺陷和浅层网络特征构造能力有限的问题,一些研究人员开始尝试采用新的参数训练方法来训练多隐藏层的深度网络。

1984年,日本学者福岛邦彦提出了卷积神经网络的原始模型神经感知机(Neocognitron)。

1998年,杨立昆提出了深度学习常用模型之一——卷积神经网络(Convolutional Neural Network,CNN)。

2006年,G. 辛顿提出了深度学习的概念,随后与其团队在文章“A Fast Learning Algorithm for Deep Belief Nets”中提出了深度学习模型之一——深度信念网络,并给出了一种高效的半监督算法——逐层贪心算法,来训练深度信念网络的参数,打破了长期以来深度网络难以训练的僵局。从此,深度学习的大门打开,在各大政府、高校和企业中掀起了研究深度学习的大浪潮。

2009年,Y. 本希奥(Y. Bengio)提出了深度学习的另一常用模型——堆叠自动编码器

(Stacked Auto-Encoder, SAE), 采用自动编码器来代替深度信念网络的基本单元——限制玻尔兹曼机, 来构造深度网络。

约翰·霍普菲尔德(John Hopfield)1982年提出了 Hopfield 网络, 是最早的递归神经网络(Recurrent Neural Network, RNN)。因 Hopfield 网络实现困难, 没有合适的应用场景, 1986年后逐渐被前向神经网络取代。

1990年, 出现了 Elman 和 Jordan SRN 两种新的 RNN, 同样因为没有合适的应用场景, 很快淡出了研究人员的视线。Dalle Molle 人工智能研究所的主任 Jürgen Schmidhuber 指导他的学生 Sepp Hochreiter 在论文“The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions”中提出了 LSTM, 促进了循环神经网络的发展, 特别是在深度学习广泛应用的今天, RNN(LSTM)在自然语言处理领域, 如机器翻译、情感分析、智能对话等取得了令人惊异的成绩。

深度学习自 2006 年产生之后就受到科研机构、工业界的高度关注。最初, 深度学习的应用主要是在图像和语音领域。

从 2011 年开始, Google 研究院和微软研究院的研究人员先后将深度学习应用到语音识别, 使识别错误率下降了 20%~30%。

2012 年, G. 辛顿的学生 I. 苏茨克弗和 A. 克里热夫斯基在图片分类比赛 ImageNet 中使用深度学习打败了 Google 团队。深度学习的应用使得图片识别错误率下降了 14%。

2012 年 6 月, Google 首席架构师 J. 迪安和斯坦福大学教授 A. 吴恩达主导著名的 GoogleBrain 项目, 采用 16 万个 CPU 来构建一个深层神经网络, 并将其应用于图像和语音的识别, 最终大获成功。此外, 深度学习在搜索领域也获得广泛关注。如今, 深度学习已经在图像、语音、自然语言处理、CTR 预估、大数据特征提取等方面获得广泛的应用。

科学家精神传承: 从感知机到深度学习, 神经网络的发展史彰显了科学探索的艰辛。我国科学家在神经网络理论(如吴文俊的“数学机械化”思想)和应用中作出重要贡献。同学们要传承科学家精神, 勇攀科技高峰, 服务国家安全与社会治理。

5.1.3 神经网络的前沿热点

神经网络的前沿热点可以从以下几方面概括。

(1) 基础理论和生理层面的深入研究。

尽管神经网络的研究已经取得了很多成果, 但其在基础理论和生理层面的研究仍需深入。例如, 神经元的动态行为、神经网络的连接权重等方面仍然需要进一步的研究。这些研究不仅有助于我们更好地理解神经网络的工作原理, 也可以为神经网络的设计和应用提供更多的启示。

(2) 与其他技术的结合。

神经网络正在与许多其他技术结合, 如进化计算技术、模糊系统、遗传算法等。这些结合可以产生混合方法和混合系统, 具有更强的适应性和鲁棒性。此外, 神经网络和生物启发的计算方法的结合, 如 DNA 计算、量子计算等, 也将为神经网络的发展带来新的机遇。

(3) 可解释性和透明度。

随着神经网络在各个领域的广泛应用, 其可解释性和透明度成为一个重要的问题。目

前,很多研究工作正在致力于提高神经网络的可解释性,如通过可视化技术、解释性算法等手段来帮助人们更好地理解神经网络的行为。

(4) 应用领域的拓展。

神经网络的应用领域正在不断扩大。在多媒体技术、医疗、金融、电力系统等领域,神经网络的应用已经取得了很大的成功。随着技术的进步和应用场景的拓展,神经网络在这些领域的应用将会更加深入。

(5) 新型神经网络模型和算法的研究。

随着技术的发展,新型的神经网络模型和算法也在不断涌现。例如,卷积神经网络、循环神经网络、生成对抗网络等都是近年来备受关注的新型神经网络模型和算法。这些新型模型和算法的出现,为解决一些复杂的认知任务提供了新的可能。

(6) 硬件加速和优化。

随着神经网络的规模越来越大,其对计算资源的需求也日益增加。因此,如何对神经网络进行高效的硬件加速和优化成为当前的研究热点。例如,专门为神经网络设计的 ASIC 芯片、GPU 加速库等都是目前的研究热点。

(7) 多模态数据处理。

随着多模态数据的大量出现,如何有效地处理这些数据并从中提取出有用的信息成为当前的研究热点。神经网络具有强大的多模态数据处理能力,因此在该领域的研究也备受关注。

(8) 隐私和安全。

随着神经网络在各个领域的广泛应用,其隐私和安全问题也日益突出。目前,很多研究工作正在致力于保护神经网络的隐私和安全,例如,通过加密技术和差分隐私技术等手段来保护用户的数据隐私。

5.1.4 神经网络的学习方法

神经网络的学习方法涵盖了一系列技术和策略,旨在通过数据来训练网络以完成特定任务。以下是几种常见的学习方法。

1. 监督学习

在监督学习中,网络通过输入数据和相应的标签进行训练,目标是使网络的输出尽可能接近标签。常见的监督学习任务包括分类和回归。

2. 无监督学习

与监督学习不同,无监督学习不使用标签进行训练。其目标是使网络发现数据中的模式和结构,常见的任务包括聚类和降维。

3. 半监督学习

半监督学习结合了监督学习和无监督学习的特点,利用少量标记数据和大量未标记数据进行训练。这种方法旨在利用未标记数据来提高模型的性能。

4. 强化学习

在强化学习中,网络通过与环境的交互来学习如何做出决策以获得最大的奖励。该方法常用于解决序列决策问题,如游戏和机器人控制。

5. 迁移学习

迁移学习旨在将已学习的知识从一个任务或领域转移到另一个任务或领域,以提高模

型在新任务或领域的性能。这对于在新任务中仅有少量标记数据的情况特别有用。

6. 元学习

元学习涉及训练模型以快速适应新任务或环境。在元学习中,模型学会如何学习,以便在面对新任务时能够更快地适应。

7. 自监督学习

自监督学习是一种无须人工标注的大规模标记数据进行训练的学习方法。它通过利用数据本身的内在结构或关联性质来进行学习,而不需要外部标签。例如,在图像领域,可以通过图像的旋转、剪切、颜色变换等方式来生成对输入图像的伪标签,然后训练模型来预测这些伪标签,从而学习到图像的特征表示。自监督学习的关键在于设计好的自监督任务,以便能够促使模型学习到有意义的特征表示。

5.1.5 神经网络的研究趋势

1. 可解释性

随着深度学习模型在各种任务上的广泛应用,人们对模型内部决策过程的理解需求越来越迫切。可解释性研究旨在使机器学习模型的决策过程更加透明和可解释。这对于许多关键领域,如医疗诊断、金融预测等具有重要意义。研究人员正在探索各种技术和方法,包括特征可视化、模型解剖、敏感性分析等,以提高模型的可解释性。

2. 可视化

可视化技术对于理解和解释深度学习模型的决策过程至关重要。通过将模型的内部表示、特征映射等可视化成易于理解的形式,研究人员和从业者可以更好地理解模型在输入数据上的操作和推理过程。可视化技术不仅有助于发现模型的弱点和潜在问题,还可以提供直观的方式来与非专业人士共享模型的工作原理。

3. 迁移学习

迁移学习旨在将一个领域中学到的知识迁移到另一个相关领域,以改善目标任务的性能。在迁移学习中,通常存在一个源领域和一个目标领域。源领域是模型已经学习到的数据和知识的来源,而目标领域则是我们希望将这些知识应用到的新任务或新领域。通过迁移学习,可以在目标领域中利用源领域的知识来加速模型的训练过程,特别是在目标领域数据较少或者标注困难的情况下。

4. 元学习

元学习则是让模型具有学习如何学习的能力。在元学习中,模型观察和学习大量不同任务的训练过程,从中总结出通用的学习规律或策略。这些学习到的规律可以帮助模型更快地适应新的任务或新的领域,从而提高模型的泛化能力和适应性。

5. 生成式模型

如生成对抗网络(GAN)和变分自编码器(VAE),旨在学习数据的分布,并能够生成与真实数据相似的新样本。这种模型在图像生成、文本生成等任务中取得了巨大成功。GAN由生成器和判别器组成,通过对抗训练的方式,使生成器不断生成逼真的样本,而判别器则不断提高识别真实样本的能力,最终达到平衡。VAE则通过学习数据的潜在表示来实现数据生成,同时还能够进行有效的数据压缩和重建。

6. 对抗性学习

对抗性学习专注于处理对抗性样本和对抗性攻击,以提高模型的鲁棒性和安全性。对抗性样本是对模型产生误导的输入,它们被设计成在人类难以察觉的情况下改变模型的输出。对抗性攻击则是针对模型的攻击手段,旨在通过微小的、人类难以察觉的修改来改变模型的决策结果。对抗性学习致力于研究和设计对抗性鲁棒的模型,以应对这些攻击。

7. 多模态学习

多模态学习是一种涉及多种类型数据联合建模的技术,旨在帮助模型更全面地理解和应用信息。在多模态学习中,模型可以同时处理图像、文本、语音等不同类型的数 据,并从中获取更深层次的语义信息和关联性。这种方法在许多应用中都具有重要意义。例如,在视觉问答(Visual Question Answering, VQA)任务中,模型需要理解图像内容并根据相关问题给出答案。多模态学习可以让模型同时考虑图像和问题的信息,从而提高答案的准确性。在图像描述生成任务中,模型需要根据图像生成自然语言描述,多模态学习可以让模型将图像内容和语言结构有机地结合起来,生成更加准确和生动的描述。另外,多模态学习还可以应用于情感分析、跨模态推理、多模态检索等领域。通过联合建模不同类型的数据,模型可以更好地理解数据之间的关联性,从而提高各种任务的性能。在实践中,多模态学习通常涉及设计复合型的神经网络结构,同时考虑不同类型数据的特征提取和融合。这种方法需要处理不同数据类型之间的异构性和相关性,因此也是一个具有挑战性的研究方向。

5.2 感知机

感知机,是 F. 罗森布拉特在 1957 年就职于康奈尔航空实验室时所发明的一种人工神经网络。感知机可以被视为前馈式人工神经网络中最简单的形式,是一种二元线性分类器,可以用于将数据进行分类。

感知机学习算法有多种常见的方法,其中包括最小二乘法和梯度下降法等。例如,梯度下降法是感知机常用的学习算法之一,它通过对损失函数进行极小化来求解感知机模型。通过这种方法,可以找到一个能够将训练数据进行线性划分的超平面,并用这个超平面构建出感知机模型。

5.2.1 单层感知机

单层感知机可以看作一个单层的神经网络,仅由输入层和输出层构成,如图 5-3 所示。其基本结构由输入层和输出层组成。输入层接收各种输入特征,并将它们传递给输出层进行处理和分类。每个输入特征都与一个权重相连,这些权重用于计算加权和。然后,将加权和传递给激活函数进行非线性转换,最终得到输出结果。

单层感知机的模型可以简单地表示为

$$f(x) = \text{sign}(\mathbf{w}^T \mathbf{x} + b)$$

$\text{sign}(x)$ 函数为阶跃函数,其表达式为

$$\text{sign}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases}$$




图 5-3 单层感知机网络示意图

单层感知机会通过权重 w 与偏置 b , 将输入数据映射到一个新的特征空间中, 再由阶跃函数对这个新的特征空间进行判断, 若小于 0, 则映射为 -1 ; 若大于或等于 0, 则映射为 1。通过这种方式来完成分类任务。

单层感知机的核心在于如何确定权重 w 与偏置 b , 我们可以利用现有的训练数据, 不断地对感知机中的 w 与 b 进行修正, 以达到最佳的拟合效果。常用的算法有最小二乘法与梯度下降法。

5.2.2 多层感知机

多层感知机是一种前馈神经网络, 由多个层次的神经元组成。最基本的结构包括输入层、若干隐藏层和输出层。每个神经元都与上一层的所有神经元相连, 每条连接都有一个权重, 而每个神经元都有一个偏置。通过对权重和偏置的学习, 多层感知机可以自动捕捉输入数据中的复杂模式, 实现从输入到输出的映射。

多层感知机相较于单层感知机, 在输入层和输出层的中间加入了一个或多个隐藏层, 每个隐藏层都有多个神经元, 如图 5-4 所示。这些隐藏层使得多层感知机能够学习更为复杂的非线性关系, 从而更好地适应现实世界中的复杂模式和数据。




图 5-4 多层感知器网络示意图

对于单层感知机, 由于线性限制, 单层感知机无法捕捉复杂的非线性关系, 因此, 在处理实际问题时受到很大的局限。而对于多层感知机, 通过多个隐藏层, 多层感知机可以学习到更复杂的特征表示, 使其能够处理更加抽象和复杂的模式。这使得多层感知机在图像识别、自然语言处理等领域表现出色。

多层感知机的训练通常采用反向传播算法和梯度下降优化。反向传播通过计算预测误差, 并反向传递误差来更新网络的权重和偏置。梯度下降则是一种通过最小化损失函数来调整模型参数的方法。这一训练过程在大规模数据集上进行, 通过迭代逐渐提升模型性能。为了防止过拟合, 常常使用正则化技术和随机失活方法。



5.3 全连接神经网络

全连接神经网络是一种基础的神经网络结构。在全连接神经网络中,每个神经元都与上一层的所有神经元和下一层的所有神经元相连接,形成了一个密集的连接结构。这意味着输入和输出之间的连接是全连接的,每个神经元都接收上一层所有神经元的输出,并将自己的输出传递给下一层的所有神经元。

5.3.1 全连接神经网络与多层感知机

全连接神经网络和多层感知机实际上可以表示相同的网络结构,这两个术语有时被用来指代同一种类型的神经网络。全连接神经网络泛指任何神经网络结构中的层次,其中每个神经元都与上一层的所有神经元相连接。这意味着输入和输出之间的连接是全连接的。全连接神经网络可能包含多个隐藏层,也可能只有一个。在全连接神经网络中,每个神经元都与前一层和后一层的所有神经元相连接,形成一个密集的连接结构。全连接神经网络能够学习输入数据的复杂特征,并进行分类、回归等任务。在实际使用中,全连接神经网络与多层感知机这两个术语经常被互换使用,而且对于大多数情况来说,它们基本上是等价的。当提到全连接神经网络时,可能是指任意结构的神经网络;而当提到多层感知机时,可能强调网络中包含多个隐藏层。

5.3.2 全连接神经网络的结构

全连接神经网络可以理解为一个多层感知机,主要结构如下。

输入层: 输入层负责接收原始数据,并将其传递给下一层。输入层的神经元数量取决于输入数据的维度。

隐藏层: 隐藏层是全连接神经网络中的中间层,可以有多个。隐藏层的神经元数量可以自由设定,每个神经元都与前一层和后一层的所有神经元相连接。

输出层: 输出层是全连接神经网络的最后一层,负责输出网络的预测结果。输出层的神经元数量取决于任务的类型,例如,二分类任务的输出层通常有一个神经元,多分类任务的输出层有多个神经元。

激活函数: 激活函数用于引入非线性因素,使得神经网络能够拟合复杂的非线性关系。常见的激活函数有 ReLU、Sigmoid、Tanh 等。

全连接神经网络在深度学习中被广泛应用,它的灵活性使得它适用于各种任务,包括图像分类、语音识别、自然语言处理等。虽然在某些复杂的视觉和时序任务上,全连接神经网络可能不如为某一任务专门设计的结构,如卷积神经网络和循环神经网络表现出色,但作为深度学习的基础知识之一,全连接神经网络为理解和构建更复杂的神经网络提供了基础。在实际应用中,全连接神经网络与多层感知机这两个术语常常混用,表示一种通用的、具有多层结构的神经网络。总体而言,全连接神经网络的理论基础和实际应用使得它成为深度学习中不可或缺的一部分。



5.4 BP 神经网络

BP(Back Propagation,反传)神经网络是1986年由D.鲁梅尔哈特和J.麦克莱兰为首的科学家提出的概念,是一种按照误差逆向传播算法训练的多层前馈神经网络,是应用最广泛的神经网络模型之一。

在人工神经网络的发展历史上,多层感知机网络曾对人工神经网络的发展发挥了极大的作用,也被认为是一种真正能够使用的人工神经网络模型,它的出现曾掀起了人们研究人工神经网络的热潮。单层感知网络作为最初的神经网络,具有模型清晰、结构简单、计算量小等优点。但是,随着研究工作的深入,人们发现它还存在不足,例如,无法处理非线性问题,即使计算单元的作用函数不用阈函数而用其他较复杂的非线性函数,仍然只能解决线性可分问题,不能实现某些基本功能,从而限制了它的应用。增强网络的分类和识别能力、解决非线性问题的唯一途径是采用多层前馈网络,即在输入层和输出层之间加上隐藏层。构成多层前馈感知机网络。

20世纪80年代中期,D.鲁梅尔哈特、G.辛顿和R.威廉斯、D.帕克等人分别独立发现了误差反向传播算法(Error Back Propagation Training),简称为BP,系统地解决了多层神经网络隐藏层连接权学习问题,并在数学上给出了完整推导。人们把采用这种算法进行误差校正的多层前馈网络称为BP网。

BP神经网络具有对任意复杂的模式的分类能力和优良的多维函数的映射能力,解决了简单感知机不能解决的异或(Exclusive OR,XOR)和一些其他问题。从结构上讲,BP网络具有输入层、隐藏层和输出层。从本质上讲,BP算法就是以网络误差二次方为目标函数,采用梯度下降法来计算目标函数的最小值。

BP网络是在输入层与输出层之间增加若干层(一层或多层)神经元,这些神经元称为隐藏单元,它们与外界没有直接的联系,但其状态的改变,则能影响输入与输出之间的关系,每一层可以有若干个节点。

BP神经网络的核心是反向传播算法,反向传播算法是目前用来训练人工神经网络的最常用且最有效的算法,反向传播算法的主要思想是:将训练集数据输入BP神经网络的输入层,经过隐藏层,最后达到输出层并输出结果,由于BP神经网络的输出结果与实际结果有误差,则先计算估计值与实际值之间的误差,并将该误差从输出层向隐藏层反向传播,直至传播到输入层。在反向传播的过程中,根据误差调整各种参数的值,不断迭代上述过程,直至收敛。

反向传播是梯度下降的一种,许多教科书中通常互换使用这两个术语。梯度下降是指针对每个训练元素,在神经网络中的每个权重上计算一个梯度。由于神经网络不会输出训练元素的期望值,因此每个权重的梯度将提示如何修改权重以实现期望输出。如果神经网络确实输出了预期的结果,则每个权重的梯度将为0,这表明无须修改权重。

梯度是权重当前值下误差函数的导数。误差函数用于测量神经网络输出与预期输出的差距。实际上,可以使用梯度下降,在该过程中,每个权重的梯度可以让误差函数达到更低值。

梯度实质上是误差函数对神经网络中每个权重的偏导数。每个权重都有一个梯度,即