

微积分基础

数学是所有工科专业的基石,其中微积分是高等数学的重点内容,也是解决现实中很多复杂问题的理论基础。在人工智能领域,微积分有着非常广泛的应用,包括图像处理、数据挖掘、深度学习、优化问题求解等。本章作为本书的开篇,将深入浅出地引领读者了解微积分的核心思想,并介绍微积分在人工智能领域中几个常见的应用案例,为后续章节的学习打下基础。

1.1 微积分的核心思想

导数和极限共同揭示了微积分的核心思想——无限分割后对一阶导数进行累加,做到“以直代曲”。为了深入浅出地阐明这一核心思想,本节将给出两个简单的案例——正弦函数面积和圆面积的累加计算,由此说明一阶导数在微积分中所发挥的作用。最后从泰勒展开式的角度,给出“以直代曲”的理论解释,循序渐进地引导读者学习微积分。

1.1.1 案例:正弦函数面积的累加计算

当 $x \in [0, \pi]$ 时,正弦函数 $\sin x$ 与 x 轴围成一个封闭的区域,它的面积是

$$\int_0^{\pi} \sin x \, dx = -\cos x \Big|_0^{\pi} = -\cos \pi + \cos 0 = 2 \quad (1-1)$$



正弦函数面积
的累加计算

式(1-1)运算结果也就是这个区域面积的理论值,称为**解析解**。变量 x 在定义域 $[0, \pi]$ 内被分成无穷多份,每份是 dx ,称为**微元**^[1]。自变量 x 取不同的值,会带来 $\sin x$ 的变化。微积分的实质是分割后再累加,所以式(1-1)的积分,就是将 x 在 $[0, \pi]$ 内无限分割,再将不同取值情况下的 $\sin x$ 做无限累加。

在计算机中实现积分计算,无法做到无限分割,毕竟物理硬件的容量有限,但是可以用有限的分割累加逼近积分的理论值,累加的结果称为**数值解**^[2]。用 Python 语言编程实现这个封闭区域面积的分割累加,具体思路如下。

将定义域 $x \in [0, \pi]$ 均匀分割成 N 等份(观察 N 取 20、100、200、500 四种情况), 每等份在 x 轴上的宽度为 $\Delta x = \frac{\pi}{N}$, 即 $\Delta x = x_{i+1} - x_i (i=0, 1, \dots, N-1)$, 每等份的面积是 $\sin x_i \cdot \Delta x$ 。将分割后的 N 等份面积累加, 可大致得到该封闭区域的总面积, 即

$$S = \sum_{i=0}^{N-1} \sin x_i \cdot \Delta x \quad (1-2)$$

代码实现如下:

【代码 1-1】

```
import numpy as np
import matplotlib.pyplot as plt
import matplotlib as mpl
if __name__ == "__main__":
    mpl.rcParams['font.sans-serif'] = 'SimHei'
    N = 200          # N 分别取 20、100、200、500 进行编译运行
    begin_point = 0
    end_point = np.pi
    Delta_x = (end_point - begin_point)/N
    X = np.linspace(begin_point, end_point - Delta_x, N)
    Y = np.sin(X)
    Area = np.sum(Y) * Delta_x
    print(Area)
    plt.figure()
    plt.plot(X, Y, 'r-')
    plt.bar(X, Y, width=Delta_x)
    plt.xlim([X.min() - 0.1, X.max() + 0.1])
    plt.ylim([Y.min() - 0.1, Y.max() + 0.1])
    plt.title(r'N=%d, 面积 $\approx$ %.5f' % (N, Area))
    plt.show()
```

运行代码 1-1 后, 得到式(1-2)的累加结果, 如图 1-1 所示。当 $N = \{20, 100, 200, 500\}$ 时, 保留小数点后 5 位, 积分结果分别为 1.99589、1.99984、1.99996 和 1.99999。随着 N 的增大, 累加结果越来越接近理论值。




图 1-1 函数 $f(x) = \sin x$ 在 $x \in [0, \pi]$ 中的积分




图 1-1(续)

1.1.2 案例:圆面积的累加计算

本小节将给出圆面积的累加计算,旨在通过此案例深入分析一阶导数在微积分中所发挥的作用。由 1.1.1 小节可知, $\sin x$ 是 $-\cos x$ 的一阶导数,封闭区域的面积就是 $\sin x$ 在 $x \in [0, \pi]$ 内的积分结果。将 $[0, \pi]$ 分割成 N 等份后对一阶导数进行累加, N 越大,即分割越精细,累加结果越精确。

众所周知,圆面积是关于 R 的函数(R 为圆的半径),这里记作 $S(R) = \pi R^2$,而周长 $2\pi R$ 是面积关于半径的一阶导数。类似于 1.1.1 小节,此案例把 r 看作变量,将其在 $[0, R]$ 内等距分割成 n 小段,如图 1-2 所示。每小段长度都是 Δr ,满足 $\Delta r = \frac{R}{n}$,即 $\Delta r = r_i - r_{i-1}$ ($i=1, 2, \dots, n$),其中 $r_0=0, r_1=\Delta r, r_2=2\Delta r$,以此类推, $r_n=n\Delta r=R$ 。


图 1-2 半径为 R 的圆

图 1-2 中粗圆环面积 $S(r+\Delta r) - S(r) = \pi(r+\Delta r)^2 - \pi r^2 = 2\pi r \Delta r + \pi \Delta r^2$ 。当 $n \rightarrow \infty$ 时, $\Delta r \rightarrow 0$,而 $\Delta S(r) = S(r+\Delta r) - S(r)$ 与 Δr 的比值是

$$\lim_{\Delta r \rightarrow 0} \frac{\Delta S(r)}{\Delta r} = \frac{2\pi r \Delta r + \pi \Delta r^2}{\Delta r} = 2\pi r \quad (1-3)$$

式(1-3)是 S 关于 r 的一阶导数。当 $r=r_i$ 时,其一阶导数为

$$\lim_{\Delta r \rightarrow 0} \frac{\Delta S(r)}{\Delta r} \bigg|_{r=r_i} = \frac{2\pi r_i \Delta r + \pi \Delta r^2}{\Delta r} = 2\pi r_i \quad (1-4)$$

式(1-4)与图 1-2 一致,即 r_i 越大,圆环 $\Delta S(r_i)$ 的面积也越大。整个圆的面积就是将这 n 个大小不等的圆环累加起来的结果,当 $n \rightarrow \infty$ 时,圆面积为

$$S(R) = \pi R^2 = \lim_{n \rightarrow \infty} \sum_{i=1}^n \Delta S(r_i) = \lim_{n \rightarrow \infty} \sum_{i=1}^n 2\pi r_i \Delta r + \pi \lim_{n \rightarrow \infty} \sum_{i=1}^n \Delta r^2 \quad (1-5)$$

式(1-5)中,最右边一项 $\lim_{n \rightarrow \infty} \sum_{i=1}^n \Delta r^2 = \lim_{n \rightarrow \infty} n \left(\frac{R}{n} \right)^2 = \lim_{n \rightarrow \infty} \frac{R^2}{n} = 0$,还原到微积分,即

$$S(R) = \lim_{n \rightarrow \infty} \sum_{i=1}^n \Delta S(r_i) = \int_0^R dS(r) = \int_0^R 2\pi r dr = \pi r^2 \Big|_0^R = \pi R^2 \quad (1-6)$$

式(1-6)中圆面积 $S(R)$ 的积分思想是:将变量 r 在 $[0, R]$ 内做无限分割,每一份是微元 dr (即 $n \rightarrow \infty$ 时 $\Delta r \rightarrow 0$ 的情况),再将 r 在不同取值下的圆环 $dS(r_i) = 2\pi r_i dr$ ($i=1, 2, \dots, n$) 做累加。这与 1.1.1 小节中正弦函数面积的累加计算的思想相同,即对一阶导数与变量微元的乘积结果做累加,二阶及以上导数忽略不计。

1.1.3 “以直代曲”的泰勒展开解释

微积分是将自变量在一定范围内无限分割后得到微元,再将自变量不同取值下的一阶导数与微元的乘积做累加。实际上,一阶导数只是函数的一部分,而非全部。本小节将把前两小节内容展开理论延伸,由泰勒展开式出发,给出函数的完整表达式,并以二次函数曲线为例,揭示一阶导数的实质——函数的线性变化(直线)部分。最后,本小节将直观展示一阶导数的累加如何实现曲线积分。

对于 n 阶可导的函数 $f(x)$,它在任一点 x_0 处的泰勒展开式为

$$f(x) = f(x_0) + (x - x_0)f'(x_0) + \frac{1}{2!}(x - x_0)^2 f''(x_0) + \dots + \frac{1}{n!}(x - x_0)^n f^{(n)}(x_0) \quad (1-7)$$

式(1-7)中 x_0 已知,而 x 是变量。令 $\Delta x = x - x_0$,则 $f(x) - f(x_0)$ 是关于 Δx 的函数,即

$$f(x) - f(x_0) = \Delta x f'(x_0) + \frac{1}{2!} \Delta x^2 f''(x_0) + \dots + \frac{1}{n!} \Delta x^n f^{(n)}(x_0) \quad (1-8)$$

不管函数 $f(x)$ 几阶可导,也不管 $|\Delta x|$ 有多大,式(1-8)都恒成立。感兴趣的读者可参阅文献[3],其作者是已故的日本数学家高木贞治,他由拉格朗日中值定理出发,经过严格的理论推导,证明出泰勒展开式对一切函数皆成立。

由式(1-8)可知,一阶导数是函数的线性变化(直线)部分。举个例子,如图 1-3 所示,二次函数 $f(x) = ax^2 + bx + c$ 呈曲线形状,令直线 $y(x) = f(x_0) + (x - x_0)f'(x_0)$,它是 $f(x)$ 在点 x_0 处的切线。




图 1-3 二次函数 $f(x) = ax^2 + bx + c$ 示意图



曲线积分

运用式(1-8)对 $f(x)$ 做泰勒展开,再结合图 1-3,在 x_1 与 x_0 两点上(令 $\Delta x = x_1 - x_0$),

函数值的差值 $f(x_1) - f(x_0)$ 包含两部分, 即一阶部分和二阶部分。

一阶部分

$$y(x_1) - f(x_0) = f'(x_0) \Delta x$$

二阶部分

$$f(x_1) - y(x_1) = \frac{1}{2!} f''(x_0) \Delta x^2$$

由于 x_0 处一阶导数是 $f'(x_0) = 2ax_0 + b$, 二阶导数是 $f''(x_0) = 2a$, 两部分合在一起即是 $f(x_1) - f(x_0) = (2ax_0 + b) \Delta x + a \Delta x^2$ 。随着 x_1 不断向 x_0 靠近或远离, $|\Delta x|$ 会减小或增大, 其中 $(2ax_0 + b) \Delta x$ 的变化与 $|\Delta x|$ 呈线性关系; 而 $a \Delta x^2$ 的变化与 $|\Delta x|$ 呈二次非线性关系, 这与式(1-5)最右边一项的情况完全一样。当 $|\Delta x| \rightarrow 0$ 时, 图 1-3 中 $f(x_1) - f(x_0) \rightarrow (2ax_0 + b) \Delta x$, 即一阶导数占主导作用。

图 1-3 展示的是一个二阶可导函数。对于 n 阶 ($n > 2$) 可导的函数 $f(x)$, 泰勒展开式共有 n 项, 三阶部分的变化与 $|\Delta x|$ 呈三次关系, 四阶部分的变化与 $|\Delta x|$ 呈四次关系, 以此类推, 当 $\Delta x \rightarrow 0$ 时, 二阶导数及以上的部分都趋于 0, 即

$$\lim_{\Delta x \rightarrow 0} \frac{\frac{1}{2!} \Delta x^2 f''(x_0) + \frac{1}{3!} \Delta x^3 f^{(3)}(x_0) + \cdots + \frac{1}{n!} \Delta x^n f^{(n)}(x_0)}{\Delta x} \quad (1-9)$$

$$= \lim_{\Delta x \rightarrow 0} \Delta x \left(\frac{1}{2!} f''(x_0) + \frac{1}{3!} \Delta x f^{(3)}(x_0) + \cdots + \frac{1}{n!} \Delta x^{n-2} f^{(n)}(x_0) \right) = 0$$

只有一阶导数 $f'(x_0)$ 对函数值变化起决定性作用, 即

$$\lim_{\Delta x \rightarrow 0} f(x_1) - f(x_0) = f'(x_0) \Delta x \quad (1-10)$$

式(1-10)表明, 如果将 x 在有限区间内分成 n 等份 $x_1, x_2, \dots, x_n$, 其中 $\Delta x = x_i - x_{i-1}$ ($i = 1, 2, \dots, n$), 当 $\Delta x = x_1 - x_0 \rightarrow 0$ 时, $f(x_1) - f(x_0)$ 与 Δx 呈线性关系, 两者的比值是一阶导数 $f'(x_0)$ 。

实际上, 曲线积分也采用了“以直代曲”的核心思想。以图 1-4 中函数 $f(x) = x^3 + 0.1$ 为例, 若它在 $x \in [0, 4]$ 的曲线长度为 l , 则 l 可以近似地表达成 n 段直线累加之和。图 1-4 (a) 和 (b) 分别展示了 $n=5$ 和 $n=10$ 时, n 段直线对曲线 l 的逼近。很明显, 后者的逼近效果比前者更好。




图 1-4 $f(x) = x^3 + 0.1$ 在 $x \in [0, 4]$ 内 n 段直线累加逼近函数曲线

根据勾股定理,若第 i 段直线的长度是 $l_i (i=1,2,\cdots,n)$,它满足

$$l_i^2 = [f(x_i) - f(x_{i-1})]^2 + (x_i - x_{i-1})^2$$

n 越大, Δx 越小, l_i 也就越短。当 $n \rightarrow \infty$ 时, l 就变成了对函数 $f(x)$ 的曲线积分,即

$$\begin{aligned} l &= \lim_{n \rightarrow \infty} \sum_{i=1}^n l_i = \lim_{n \rightarrow \infty} \sum_{i=1}^n \sqrt{[f(x_i) - f(x_{i-1})]^2 + (x_i - x_{i-1})^2} \\ &= \lim_{n \rightarrow \infty} \sum_{i=1}^n \sqrt{f'(x_i)^2 + 1} \Delta x \\ &= \int_0^4 \sqrt{f'(x)^2 + 1} dx \end{aligned}$$

1.2 导数的近似估计

由 1.1 节可知,将变量的一阶导数做累加可以得到原函数。在此基础上,本节将做出相反的操作——给变量加上一点变动,根据函数值变化与变量变化的比值,近似地估计一阶导数和二阶导数,这种方法称作有限差分法。另外,本节也将给出有限差分法的两个应用案例——正弦函数导数的有限差分估计和图像边缘(轮廓)提取。

1.2.1 有限差分法

1.1 节阐明了微积分的核心思想——无限分割后将一阶导数累加,做到“以直代曲”。具体来说,它是将自变量 $x \in [a, b]$ 分割成 N 等份,当 $N \rightarrow \infty$ 时,则 $\Delta x = \frac{b-a}{N} \rightarrow 0$ 。如果 $f(x)$ 是 $F(x)$ 的一阶导数,不管 $F(x)$ 多少阶可导,式(1-11)均成立,即

$$F(b) - F(a) = \int_a^b f(x) dx = \lim_{N \rightarrow \infty} \sum_{i=1}^N f(x_i) \Delta x \quad (a \leq x_i \leq b) \quad (1-11)$$

这种只用一阶导数的逼近方法,在学术界称为欧拉法^[2]。1.1.1 小节正弦函数积分的案例表明, Δx 越小,欧拉法的逼近越精确。

受到欧拉法的启发,可以进行相反的操作——将 x 取任一固定的值 x_0 ,稍作扰动变为 $x_1 = x_0 + \Delta x$ 。根据函数差值 $F(x_1) - F(x_0)$ 与变量差值 Δx 的比例关系,近似估计一阶导数 $f(x_0)$,这种方法称作有限差分法^[4]。很多实际问题都可以采用有限差分法代替函数的真实导数,近似描述函数的真实变化情况。

常见的有限差分法有一阶导数的前向差分估计和后向差分估计,以及二阶导数的中心差分估计,计算式分别为

$$f'(x_i) \approx \frac{f(x_{i+1}) - f(x_i)}{\Delta x} \quad (1-12)$$

$$f'(x_i) \approx \frac{f(x_i) - f(x_{i-1})}{\Delta x} \quad (1-13)$$

$$f''(x_i) \approx \frac{f(x_{i+1}) - 2f(x_i) + f(x_{i-1}))}{\Delta x^2} \quad (1-14)$$

随着 $\Delta x \rightarrow 0$, 一阶和二阶差分法都会收敛到相应导数, 但是收敛速度不同^[4]。如果固定 Δx , 二阶差分估计的精度要高于二阶。究其原因, 编著者认为, 还是应该从泰勒展开式出发, 追根溯源进行误差分析。

对于三次及以上可导的函数 $f(x)$, 泰勒展开后保留前两阶导数, 即

$$f(x_{i+1}) = f(x_i) + \Delta x f'(x_i) + \frac{1}{2} \Delta x^2 f''(x_i) + O\left(\sum_{j=3,4,5,\dots} \Delta x^j\right) \quad (1-15)$$

将式(1-15)变形, 对照式(1-12), 一阶前向差分估计的误差为

$$\frac{f(x_{i+1}) - f(x_i)}{\Delta x} - f'(x) = \frac{1}{2} \Delta x f''(x_i) + O\left(\sum_{j=2,3,4,\dots} \Delta x^j\right) = O\left(\sum_{j=1,2,3,\dots} \Delta x^j\right) \quad (1-16)$$

二阶中心差分估计的误差分为两步, 即

$$\frac{f(x_{i+1}) - f(x_i)}{\Delta x^2} = \frac{f'(x_i)}{\Delta x} + \frac{1}{2} f''(x_i) + O\left(\sum_{j=1,2,3,\dots} \Delta x^j\right) \quad ①$$

$$\frac{f(x_{i-1}) - f(x_i)}{\Delta x^2} = -\frac{f'(x_i)}{\Delta x} + \frac{1}{2} f''(x_i) + O\left(\sum_{j=1,2,3,\dots} (-1)^j \Delta x^j\right) \quad ②$$

注意: ②中, $f(x_i) - f(x_{i-1}) = \Delta x$, 所以 $f(x_{i-1}) - f(x_i) = -\Delta x$ 。

将①②相加, 对照式(1-14)可得

$$\frac{f(x_{i+1}) - 2f(x_i) + f(x_{i-1}))}{\Delta x^2} - f''(x_i) = 2O\left(\sum_{j=2,4,6,\dots} \Delta x^j\right) \quad (1-17)$$

对比式(1-16)和式(1-17), 不难发现二阶中心差分估计的误差仅仅是 Δx 的偶数次方的阶项之和, 而一阶前向差分估计的误差是关于 Δx 的所有阶次之和, 故前者精度更高。至于式(1-13)的一阶后向差分估计误差, 请读者仿照上述内容自行推导。

1.2.2 案例: 正弦函数导数的有限差分估计

文献[5]将正弦函数 $f(x) = \sin x$ 看作原函数, 在一个周期 $x \in [0, 2\pi]$ 内均匀采样 $N = 150$ 个点, 分别采用前向差分估计法和二阶中心差分估计法, 通过 C++ 与计算统一设备架构 (compute unified device architecture, CUDA) 相结合的并行编程方式, 估算一阶导数 $f'(x) = \cos x$ 和二阶导数 $f''(x) = -\sin x$ 。

本案例将对此进行拓展, 取 $N = 20, 50$ 和 100 (即 $\Delta x = \frac{2\pi}{N}$), 计算这三种情况下的估计误差, 并观察误差与 Δx 之间的关系。估计采用均方误差 (mean square error, MSE), 即 $MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$, 其中 y_i 表示第 i 个点的理论值, $\hat{y}_i$ 是估计值。

代码实现如下:

【代码 1-2】

```
import numpy as np
```

```

import matplotlib.pyplot as plt
import matplotlib as mpl
mpl.rcParams['font.sans-serif'] = 'SimHei'
plt.rcParams['axes.unicode_minus'] = False
config = {
    "font.family": 'serif',
    "font.size": 10,
    "mathtext.fontset": 'stix',
    "font.serif": ['SimSun'],
}
mpl.rcParams.update(config)
if __name__ == '__main__':
    N = 100
    Delta = 2 * np.pi / N
    Result = np.zeros((6, N), dtype=float)
    for i in range(N):
        Result[0, i] = np.sin(Delta * i)          # 原函数
        Result[1, i] = np.cos(Delta * i)          # 真实的一阶导数
        Result[2, i] = (np.sin(Delta * (i + 1)) - np.sin(Delta * i)) / Delta
                                                    # 一阶导数的前向差分估计
        Result[3, i] = (np.sin(Delta * i) - np.sin(Delta * (i - 1))) / Delta
                                                    # 一阶导数的后向差分估计
        Result[4, i] = -np.sin(Delta * i)          # 真实的二阶导数
        Result[5, i] = (np.sin(Delta * (i + 1)) - 2 * np.sin(Delta * i) + np.sin(Delta *
(i - 1))) / (Delta * Delta)                      # 二阶导数的中心差分估计
    D1 = Result[1] - Result[2]
    MSE_1 = np.mean(D1 * D1)
    print(r'一阶前向差分的误差是: %.10f' % MSE_1)
    D2 = Result[1] - Result[3]
    MSE_2 = np.mean(D2 * D2)
    print(r'一阶后向差分的误差是: %.10f' % MSE_2)
    D3 = Result[4] - Result[5]
    MSE_3 = np.mean(D3 * D3)
    print(r'二阶中心差分的误差是: %.10f' % MSE_3)
    fig = plt.figure(figsize=(6, 4))
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[0], 'k-')
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[1], 'b--')
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[2], 'c-')
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[3], 'g-x')
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[4], 'r-<')
    plt.plot(np.linspace(0, 2 * np.pi, N), Result[5], 'm-d')
    plt.legend([r'$f(x)$', r'$\cos(x)$', r'Diff_1', r'Diff_2', r'$-\sin(x)$', r'Diff_3'], loc =
0, bbox_to_anchor=(1.05, 1), borderaxespad=0, fontsize=12)
    plt.xlim([0, 2 * np.pi])
    plt.ylim([-1, 1])
    plt.xlabel(r'$x$', fontsize=12)
    fig.subplots_adjust(right=0.75)
    plt.show()

```

当 $N = 20, 50, 100$ 时, 代码 1-2 的运行效果分别如图 1-5~图 1-7 所示, 其中 Diff_1、Diff_2 和 Diff_3 分别表示 N 个点的一阶前向差分估计、一阶后向差分估计和二阶中心差分估计的结果。




图 1-5 正弦函数的有限差分估计 ($N=20$)

注: 一阶前向导差的误差是 0.0122695270

一阶后向导差的误差是 0.0122695270

二阶中心差分的误差是 0.0000336008





图 1-6 正弦函数的有限差分估计 ($N=50$)

注: 一阶前向导差的误差是 0.0019721898

一阶后向导差的误差是 0.0019721898

二阶中心差分的误差是 0.0000008649

图 1-7 正弦函数的有限差分估计($N=100$)

注：一阶前向差分的误差是 0.0004933720

一阶后向差分的误差是 0.0004933720

二阶中心差分的误差是 0.0000000541

观察图 1-5~图 1-7,随着 N 的增大, Δx 在减小,这三种差分估计方法均会越来越精确。对于一阶导数,虽然前向和后向差分估计值不同,但是这 N 个点的均方误差完全一样。与此同时,二阶中心差分估计的精度要远远高于一阶的两种情况,这与 1.2.1 小节的误差分析结果一致。

1.2.3 案例:图像边缘(轮廓)提取

在人工智能领域,导数的近似估计被广泛应用在图像处理中,最典型的应用就是图像轮廓提取,也称作边缘检测。这里,首先需要了解图像在计算机中是如何表示的。图 1-8(a)是我们肉眼所见的阿拉伯数字 2 的灰度图像,分辨率为 16×16 ,即总共 256 个像素点。在计算机中,这张图像是一个 16×16 的二维矩阵,如图 1-8(b)所示。

通常,黑色像素点在计算机中用 0 表示,白色像素点用 255 表示。介于黑白之间的像素点即为灰色,像素值用 0~255 的整数表示,越接近白色的浅灰,像素值越接近 255,反之越接近 0。在图像处理中,将图 1-8(b)所示的二维矩阵看成一个平面坐标系,水平和垂直方向分别看成 x 轴和 y 轴,每个像素点都对应一个坐标位置 (x, y) ,其像素值就是这个坐标位置上的函数值 $F(x, y)$ 。例如,第 1 行第 5 列的像素值是 76,即 $F(1, 5) = 76$ 。边缘(轮廓)提取会用到图像的导数(梯度)信息,它反映了在 x 轴和 y 轴方向上相邻两个像素值的变化程度。这其实延续了 1.2.1 小节有限差分法的思想,即根据函数值的变化近似估计导数大小。因此,边缘(轮廓)提取实际上就是遍历整个图像,找寻像素值发生突变(梯度大)的地方。

在现有的图像边缘检测提取方法中,较为常见的是 Sobel 检测、Laplacian 检测、Prewitt