

detector de contorno – boundary detector

Authored by
memjavad

November 9, 2025

RECOMMENDED CITATION

memjavad (2025). *detector de contorno – boundary detector*. Spanish Psychological Databases. Retrieved from <https://spanish.arabpsychology.com/?p=3574>

Detector de Bordes (Boundary Detector)

Primary Disciplinary Field(s): Visión por Computadora, Procesamiento Digital de Imágenes, Aprendizaje Automático, Procesamiento de Señales.

1. Definición Central

El **detector de bordes** es un algoritmo fundamental dentro del campo del **procesamiento digital de imágenes** y la visión por computadora, diseñado con el objetivo primordial de identificar puntos en una imagen digital donde la intensidad luminosa o el color experimentan un cambio abrupto y significativo. Estas discontinuidades de intensidad corresponden, en la mayoría de los casos, a los límites físicos de objetos, a cambios de superficie, o a variaciones en la iluminación o la reflectancia, constituyendo así la información estructural esencial de una escena. La detección de bordes transforma una matriz de píxeles complejos en una representación mucho más simple y compacta, que consiste únicamente en las líneas que definen la geometría de los elementos.

El resultado de la aplicación de un detector de bordes es típicamente un mapa de bordes (o mapa de contornos), que es una imagen binaria donde los píxeles blancos representan los bordes detectados y los píxeles negros representan el fondo o las regiones homogéneas. Este proceso es crucial porque la mayoría de las tareas de alto nivel en visión por computadora, como el **reconocimiento de objetos**, la segmentación y el seguimiento, dependen de una extracción precisa de estas características geométricas. Un buen detector debe ser capaz de diferenciar entre el ruido aleatorio inherente a la captura de imágenes y las variaciones de intensidad que realmente representan límites significativos.

Es importante distinguir la detección de bordes de la segmentación de imágenes. Mientras que la segmentación busca dividir la imagen completa en regiones coherentes y significativas (como "cielo", "carretera", "coche"), la detección de bordes se centra únicamente en el fenómeno local de las **discontinuidades de intensidad**. Los bordes son la base para construir límites de objetos más complejos. Un límite de objeto es una estructura global que puede ser compuesta por múltiples bordes locales, y su identificación a menudo requiere algoritmos que integran información contextual además de la información puramente local proporcionada por el detector.

2. Fundamentos Matemáticos y Físicos

Matemáticamente, un borde se modela como una región donde la función de intensidad de la imagen (entendida como una función bidimensional $I(x, y)$) presenta un alto gradiente. El concepto central para la detección de bordes es el **cálculo diferencial**. La tasa de cambio de la intensidad se mide utilizando derivadas. En dos dimensiones, esto se logra mediante el vector gradiente, que apunta en la dirección de máximo aumento de la intensidad y cuya magnitud indica

la rapidez de ese cambio. Por lo tanto, un borde se localiza en los puntos donde la magnitud del gradiente es máxima.

El cálculo del gradiente se realiza típicamente mediante la **convolución** de la imagen con kernels (o máscaras) pequeños, conocidos como filtros de diferenciación. Estos filtros son aproximaciones discretas de los operadores de derivadas parciales en las direcciones horizontal (G_x) y vertical (G_y). La magnitud del gradiente (M) y su dirección (θ) se calculan a partir de estas derivadas parciales: $M = \sqrt{G_x^2 + G_y^2}$ y $\theta = \arctan(G_y / G_x)$. Los detectores de primera generación, como Sobel o Prewitt, se basan directamente en esta aproximación del gradiente.

Debido a que la operación de diferenciación es inherentemente sensible al ruido (amplifica las altas frecuencias, donde el ruido suele residir), es indispensable aplicar un paso de suavizado o filtrado previo a la diferenciación. El filtro más comúnmente utilizado es el **filtro Gaussiano**. Este proceso de suavizado y diferenciación se combina a menudo en un único operador, como el Laplaciano del Gaussiano (LoG) o, más eficientemente, el Detector de Canny, que utiliza la derivada de una función Gaussiana. Los bordes también pueden identificarse mediante los cruces por cero de la segunda derivada, lo que indica un punto de inflexión en la función de intensidad, una propiedad explotada por el operador LoG.

3. Desarrollo Histórico y Tipologías

La historia de la detección de bordes se puede dividir en varias generaciones. Los primeros métodos, desarrollados en las décadas de 1960 y 1970, eran puramente heurísticos y se basaban en la aplicación directa de operadores de gradiente simples, como los operadores de **Roberts**, Prewitt y **Sobel**. Estos detectores utilizan ventanas pequeñas (generalmente 2x2 o 3x3) y son extremadamente rápidos, pero carecen de robustez frente al ruido y a menudo producen bordes gruesos o múltiples respuestas para un solo borde físico.

La segunda generación de detectores, que surgió en la década de 1980, se centró en la optimización teórica. El trabajo seminal de David Marr y Ellen Hildreth introdujo la idea de utilizar el **Laplaciano del Gaussiano** (LoG) para detectar bordes a diferentes escalas, basándose en la teoría del espacio de escala. Sin embargo, el avance más significativo fue el desarrollo del [Detector de Canny](#) por John F. Canny en 1986. Canny definió criterios de optimización rigurosos (buena detección, buena localización y mínima respuesta múltiple) que catapultaron su algoritmo a convertirse en el estándar de oro en la visión por computadora clásica, superando a sus predecesores en precisión y robustez.

La tercera generación, y la más reciente, integra la detección de bordes con el **aprendizaje automático** (Machine Learning) y el **aprendizaje profundo** (Deep Learning). Estos métodos, como la Detección de Bordes Holísticamente Anidada ([HED](#)), utilizan Redes Neuronales

Convolucionales (CNN) entrenadas con grandes conjuntos de datos anotados para aprender a distinguir entre bordes de objetos (bordes semánticos) y bordes causados por texturas o ruido. Este enfoque moderno aborda la principal limitación de los métodos clásicos, que es la incapacidad de la detección puramente basada en intensidad para capturar la semántica de la escena.

4. Características Clave de los Detectores

La efectividad de un detector de bordes se evalúa en función de varias características críticas. La **buena localización** es fundamental; esto significa que el borde detectado algorítmicamente debe estar lo más cerca posible del borde real del objeto en la imagen. Una localización deficiente puede llevar a errores graves en tareas subsiguientes como la medición de formas o la reconstrucción 3D. Además, la robustez es clave: el detector debe mantener su rendimiento incluso cuando la imagen está degradada por ruido, variaciones de iluminación o artefactos de compresión.

Otra característica crucial es la **supresión de no-máximos** (Non-Maximum Suppression, NMS). Dado que los operadores de gradiente a menudo producen una "cresta" de valores altos en lugar de una línea de un solo píxel, el NMS es un proceso de adelgazamiento que asegura que solo el píxel con la magnitud de gradiente máxima a lo largo de la dirección perpendicular al borde sea retenido. Esto garantiza que cada borde físico sea representado por una única línea de píxeles, mejorando la precisión geométrica de la salida.

Finalmente, la **umbralización con histéresis**, popularizada por el detector de Canny, es esencial para la conectividad de los bordes. Este método utiliza dos umbrales: uno alto y uno bajo. Los píxeles de borde cuya magnitud supera el umbral alto son considerados bordes definitivos. Los píxeles entre el umbral bajo y el alto solo se consideran bordes si están conectados a un borde definitivo. Este proceso de conexión evita la fragmentación de los bordes largos y continuos y, al mismo tiempo, minimiza la inclusión de ruido de baja magnitud.

5. Algoritmos Comunes y Ejemplos

El **Detector de Sobel** es quizás el ejemplo más simple y conocido de un detector de primera generación. Utiliza dos kernels de 3x3, uno para la dirección horizontal y otro para la vertical, que no solo calculan la derivada sino que también incorporan un ligero suavizado, lo que lo hace marginalmente más robusto al ruido que el operador de Roberts. Su principal limitación es que sus bordes son a menudo gruesos y su rendimiento se deteriora rápidamente en imágenes ruidosas o con texturas complejas.

El **Detector de Canny** es el algoritmo de referencia debido a su enfoque multifásico que intenta satisfacer los criterios óptimos. El proceso se compone de cuatro pasos rigurosos: 1) Suavizado

Gaussiano, 2) Cálculo de los gradientes (magnitud y dirección), 3) Supresión de no-máximos para adelgazar los bordes, y 4) Umbralización con histéresis para conectar y finalizar los contornos. Este rigor asegura que los bordes resultantes sean finos, bien localizados y continuos, lo que lo hace adecuado para la mayoría de las aplicaciones de visión por computadora que requieren alta precisión.

Otro método notable es el basado en el **Laplaciano del Gaussiano (LoG)**, a veces referido como el operador "Mexican Hat" debido a la forma de su kernel. Este detector utiliza la segunda derivada para localizar los bordes como cruces por cero. Aunque es conceptualmente potente, ya que la segunda derivada es menos sensible a la orientación, el LoG tiene desventajas, como la tendencia a generar bordes cerrados o anillos y una sensibilidad a los cruces por cero espurios si el suavizado no es adecuado. Por esta razón, el Detector de Canny, que utiliza la primera derivada suavizada, es generalmente preferido.

6. Aplicaciones y Significado

La detección de bordes es un paso de procesamiento de bajo nivel de inmensa importancia, actuando como el puente entre la imagen bruta y el análisis de alto nivel. Su principal significado radica en su capacidad para **reducir la dimensionalidad** de los datos. Una imagen de 1000x1000 píxeles contiene un millón de datos, pero el mapa de bordes resultante contiene solo unos pocos miles de píxeles informativos, lo que simplifica drásticamente la carga computacional para los algoritmos posteriores de reconocimiento o clasificación.

Las aplicaciones son vastas y abarcan múltiples dominios. En la **robótica** y los vehículos autónomos, los detectores de bordes se utilizan para identificar los límites de carriles, las siluetas de peatones y vehículos, y los obstáculos, facilitando la navegación segura. En la **medicina**, son cruciales para la segmentación de órganos, tumores o estructuras vasculares en imágenes de resonancia magnética (MRI) o tomografías computarizadas (CT), ayudando en el diagnóstico y la planificación quirúrgica.

Además, la detección de bordes es fundamental en la **fotogrametría** y la reconstrucción 3D. Por ejemplo, en la visión estéreo, la correspondencia de bordes entre dos imágenes tomadas desde diferentes puntos de vista es mucho más fiable que la correspondencia de píxeles individuales, ya que los bordes son menos sensibles a las variaciones de iluminación y perspectiva. También se utiliza en el control de calidad industrial para inspeccionar la integridad de los productos o verificar las dimensiones geométricas de componentes manufacturados.

7. Debates y Limitaciones

A pesar de la sofisticación de algoritmos como el de Canny, la principal limitación de los detectores de bordes clásicos reside en el **vacío semántico** (semantic gap). Los detectores

tradicionales son operadores de baja frecuencia que solo responden a cambios locales de intensidad. Esto significa que un cambio de intensidad causado por la textura de una alfombra o por una sombra proyectada se detectará con la misma fuerza que el borde real de un objeto. Esto genera una gran cantidad de bordes espurios que deben ser filtrados o interpretados contextualmente.

Otra limitación significativa es la **sensibilidad a los parámetros**. El rendimiento de la mayoría de los detectores, especialmente Canny, depende críticamente de la elección manual de parámetros, como el tamaño del kernel Gaussiano (σ) y los umbrales de histéresis. Un σ demasiado grande puede fusionar bordes cercanos, mientras que uno demasiado pequeño amplifica el ruido. La optimización de estos parámetros suele ser específica para cada imagen o conjunto de datos, lo que dificulta la generalización automática del método.

Para superar estas limitaciones, la investigación moderna se ha desplazado hacia métodos basados en el aprendizaje profundo que abordan el vacío semántico. Estos nuevos enfoques no solo detectan dónde ocurre un cambio de intensidad, sino que también aprenden a clasificar si ese borde corresponde a un límite de objeto significativo o es simplemente un artefacto de textura. Al integrar el contexto global de la imagen y la información semántica, las redes neuronales están logrando una detección de bordes mucho más robusta y significativa, aunque a costa de una mayor complejidad computacional y la necesidad de grandes volúmenes de datos de entrenamiento.

Further Reading

[Canny edge detector](#)

[Holistically-Nested Edge Detection \(HED\)](#)

[Image Gradient and Edge Detection](#)