

Estructura y operaciones con redes neuronales

1 Aprendizaje de máquina

El aprendizaje de máquina es un tipo de algoritmo que se mejora automáticamente así mismo basado en la experiencia, no por un programador que escribe un mejor programa.

Consiste esencialmente en usando un conjunto de datos de la forma $\{ \langle x^i, y^i \rangle \}_{i=1}^M$, entrenar, en lugar de programar a una máquina para que realice una tarea.

Entrenar, significa sintetizar una función que mejor represente la relación entre las entradas x^i y las correspondientes salidas y^i .

El problema central de la teoría de aprendizaje es que también esta función generaliza, por ejemplo que también estima las salidas para entradas previamente no conocidas.

1.1 Redes neuronales

Un enfoque cada vez más popular para el aprendizaje de máquina es la red neuronal. Una red neuronal opera de manera similar a como pensamos que funcionan los cerebros con entradas que fluyen a través de muchas capas de "neuronas" que eventualmente llevan a una salida. La figura 1 ilustra una red neuronal básica con dos neuronas en la capa de entrada, dos en la capa oculta y una en la capa de salida.




Figure 1: x_1, x_2 valores de neuronas de entrada, w_1, w_2, w_3, w_4 pesos asociados a las entradas.

1.2 Estructura y funcionamiento de la red neuronal

1.2.1 Estructura de la red neuronal

1. Capa de entrada (Input layer) . Dos neuronas, una para cada variable . Las neuronas de esta capa no realizan algún cálculo simplemente transmiten entradas a la capa oculta.
2. Capa oculta (Hidden layer): Dos neuronas que reciben las señales de la capa de entrada y realizan cálculos intermedios. Cada neurona en esta capa tiene sus propios pesos y sesgos que se ajustan durante el entrenamiento para aprender las características importantes de los datos.
3. Capa de salida (Output layer): Una neurona que produce la salida final de la red neuronal. Aplica una función de activación para producir un valor de salida, que podría ser una predicción en un problema de regresión o una clasificación en un problema de clasificación binaria, dependiendo del tipo de tarea.

1.2.2 Funcionamiento de la red neuronal

1. Inicialización de pesos y sesgos: Antes de que la red neuronal comience a aprender, los pesos y sesgos se inicializan aleatoriamente. Los pesos representan la fuerza de conexión entre las neuronas, mientras que los sesgos permiten que la red aprenda patrones incluso cuando todas las entradas son cero.
2. Propagación hacia adelante (Forward Propagation): Durante la fase de propagación hacia adelante, las entradas se multiplican por los pesos y se suman los sesgos en cada neurona. Luego, se aplica una función de activación, en nuestro caso la función signoide a la suma ponderada para introducir no linealidad a la red. Estos cálculos se propagan capa por capa hasta que se obtiene una salida.
3. Cálculo de la Pérdida (Loss Calculation): Se compara la salida de la red neuronal con la salida esperada utilizando una función de pérdida,

como el error cuadrático medio (MSE) para problemas de regresión o la entropía cruzada para problemas de clasificación. La función de pérdida cuantifica qué tan lejos está la salida predicha de la salida real.

4. Retropropagación del error (Backpropagation): Una vez que se calcula la pérdida, se utiliza el algoritmo de la retropropagación para calcular las derivadas parciales de la función de pérdida con respecto a cada peso y sesgo en la red. Estas derivadas se utilizan para ajustar los pesos y sesgos en la dirección que minimiza la pérdida, utilizando un algoritmo de optimización como el descenso del gradiente.
5. Actualización de los pesos y sesgos: Los pesos y sesgos se actualizan utilizando los gradientes calculados durante la retropropagación y un hiperparámetro llamado tasa de aprendizaje, que controla qué tan grandes son los pasos de actualización. Este proceso se repite iterativamente para múltiples épocas hasta que la red neuronal converge a una solución óptima o alcance un criterio de parada predefinido.
6. Predicción: Una vez que la red neuronal está entrenada, se puede utilizar para hacer predicciones sobre nuevos datos. Las entradas se propagan hacia adelante a través de la red utilizando los pesos y sesgos ajustados durante el entrenamiento, y se obtiene un resultado final de la capa de salida.

2 Operaciones con las neuronas

En el contexto de aprendizaje automático para inteligencia artificial, las operaciones que se realizan en las neuronas se pueden entender mediante el modelo matemático de una red neuronal artificial. Una neurona artificial típicamente realiza tres operaciones principales: suma ponderada, función de activación y, opcionalmente, adición de un término de sesgo (bías).

2.1 Suma ponderada

Para calcular la entrada de una neurona, primero se realiza una suma ponderada de las entradas. Sean x_1 , x_2 los valores de entrada, y w_1 , w_2 los pesos asociados a esas entradas. La suma ponderada se calcula como:

$$z = w_1x_1 + w_2x_2$$

2.2 Funciones de activación

Las funciones de activación controlan en gran medida que información se propaga desde una capa a la siguiente (propagación hacia adelante). Estas funciones convierten el valor de entrada a la neurona, combinación de entrada pesos y sesgo, en un nuevo valor. Es gracias a combinar funciones de activación no lineales con múltiples capas que los modelos de redes son capaces de aprender relaciones no lineales. Comúnmente se utiliza la función función sigmoide definida por:

$$\text{sigmoide} = \frac{1}{1 + e^{-x}}$$

que transforma valores en el rango de $(-\infty, \infty)$ a valores en el rango $(0, 1)$. La función sigmoide sigue siendo la función utilizada por defecto en las neuronas de la capa de salida de los modelos de clasificación binaria, ya que su salida puede interpretarse como probabilidades.

2.3 Sesgo (bías)

El término sesgo es un valor constante que se añade a la suma ponderada antes de aplicar la función de activación. Este término permite a la neurona ajustar su salida, incluso cuando todas las entradas son cero, proporcionando una mayor flexibilidad y capacidad. Denotamos el término de sesgo como b , y lo agregamos a la suma ponderada:

$$z = w_1x_1 + w_2x_2 + b$$




Figure 2: Estructura red neuronal con neurona ampliada.

En resumen, una neurona realiza operaciones de suma ponderada y aplicación de una función de activación para generar una salida. Estas operaciones se realizan de manera repetida en capas sucesivas para formar una red neuronal que puede aprender a realizar tareas específicas mediante la adaptación de sus pesos durante el entrenamiento.