


Para saber mais: Pooling e invariância

Enumeramos em aula algumas vantagens da subamostragem em redes convolucionais. Em termos de custo computacional, **reduzir a dimensionalidade espacial dos mapas de ativação permite uma grande economia de processamento**. Por si só essa já é uma vantagem bastante convincente para usar o pooling, pois imagens são dados de altíssima dimensionalidade.

Um dos principais livros de Deep Learning [1] define o Pooling como um "resumo estatístico" das saídas de uma convolução. Isso porque a camada **não** realiza uma subamostragem aleatória dos mapas de ativação, mas destaca as características mais relevantes de cada vizinhança local (definida pelo campo de visão do pooling).

Um importante efeito disso é que **o Pooling torna a representação aproximadamente invariante a pequenas translações**. Em termos claros, se a imagem de entrada for levemente deslocada no espaço, uma boa parte do mapa de características resultante do pooling não será alterado. A imagem a seguir mostra exemplos do mesmo objeto após translações no espaço.



Os mapas de ativação produzidos pela convolução mantêm a informação espacial da entrada, ou seja, a localização das características ativadas está fortemente relacionada à localização das regiões correspondentes. Uma imagem espacialmente deslocada terá como saída um mapa de ativação espacialmente deslocado. Com o Pooling e o seu resumo estatístico, a rede concentra seus esforços em identificar a presença de características relevantes, independentes da sua localização específica na imagem.

Vale ressaltar que a informação espacial da imagem ainda é mantida até certo nível. O exemplo dado pelo livro menciona o problema de detecção de faces. Não importa a localização precisa dos olhos, mas importa bastante saber que existe um olho do lado esquerdo da face e outro do lado direito. O Pooling preserva esse nível de informação, que para a maioria dos problemas não só é suficiente, como também é vantajoso pela adição da invariância.

[1] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. Deep learning. MIT press, 2016, pg 342.