

Hluboké učení prakticky vyřešilo nejrůznější problémy počítačového vidění v průběhu poslední dekády. V práci používáme grupy persistentní homologie z výpočetní topologie k analýze prostorů vnitřních reprezentací příznaků v konvolučních neuronových sítích (CNN). Pozorovali jsme souvislost mezi souhrny homologických persistentních grup rozhodovací hranice a chybou tréninku sítě ResNet-18 v průběhu fenoménu hlubokého dvojitého poklesu. Navíc jsme se zaměřili na zvláštní případ souhrnu, který poukazuje na analogii dvojitého sestupu ve směru epoch, což by mohlo vést lepšímu pochopení vnitřních reprezentací v průběhu kriticky parametrizovaného režimu sítě.

V hlavní části navrhuje a porovnáme několik přístupů k procesingu samotných modelů CNN sítí pomocí persistentní homologie. Naše nejlepší metoda zvaná Derivovatelný persistentní estimátor kvality (DPAE) dosahuje vysoké přesnosti v predikci kvality CNN sítí (tj. R2 skóre téměř 0.99). DPAE je topologicky optimalizovatelná end-to-end architektura zahrnující derivovatelný výpočet persistence. Co více, DPAE metoda předčí i původní metodu využívající klasického strojového učení, které byla vytvořena přímo pro dataset, který používáme k testování. Veřejně dáváme k dispozici zdrojový kód jak metody DPAE tak ostatních prezentovaných experimentů.