

Gradientové učenie hlbokých neurónových sietí

Truc Lam, Bui
Školiteľ: RNDr. Kristína Malinovská, PhD.

27. júna 2018

Ciele práce

1. Preskúmať rôzne nové spôsoby, akými sa dá hlboké učenie urýchliť.
2. Experimentálne ich vyhodnotiť.

Stručne o neurónových sietiach

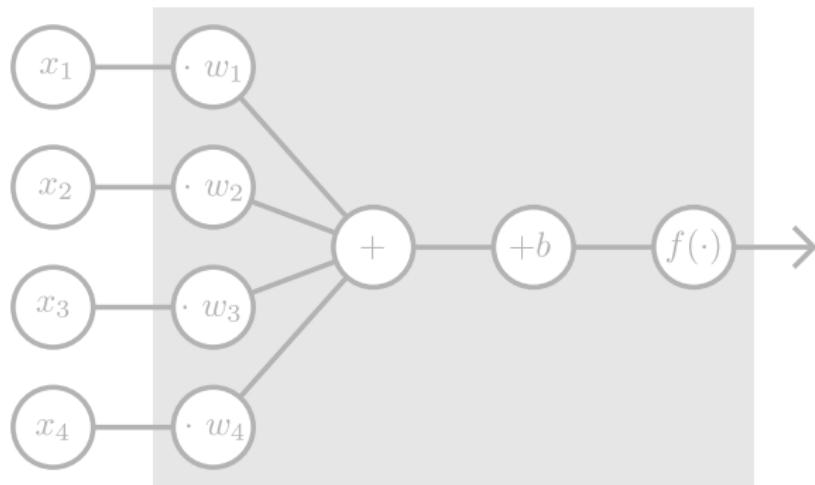
Čo? Načo?



žaba
lietadlo
auto
...

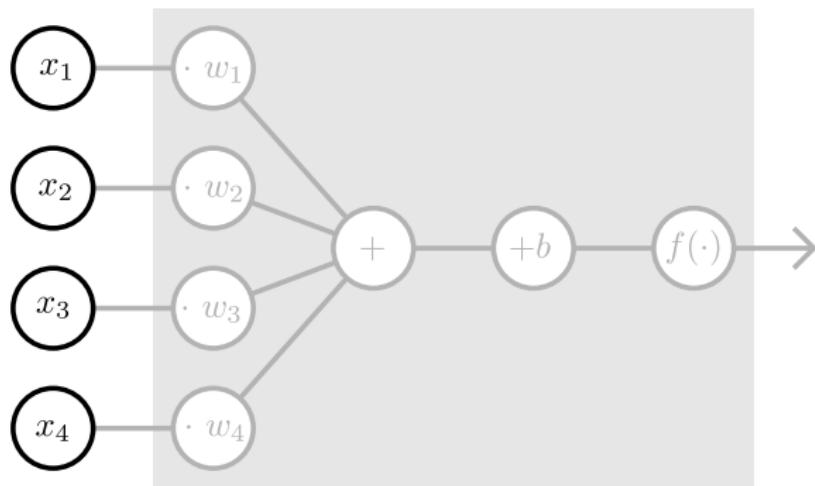
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



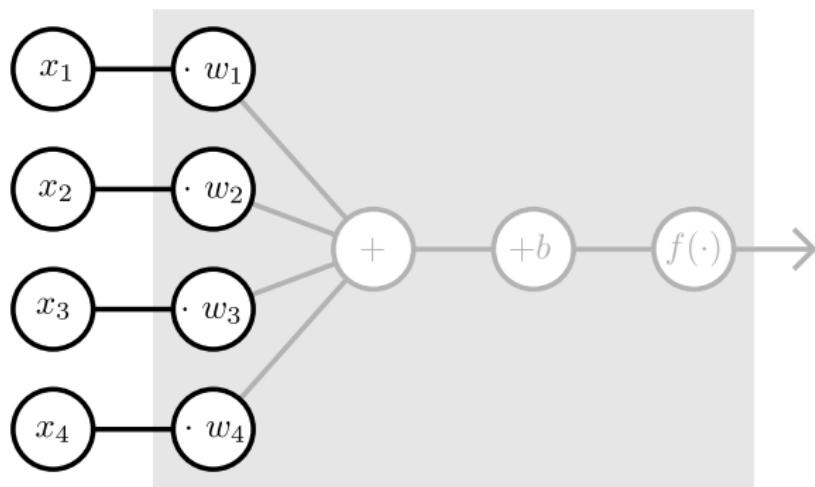
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



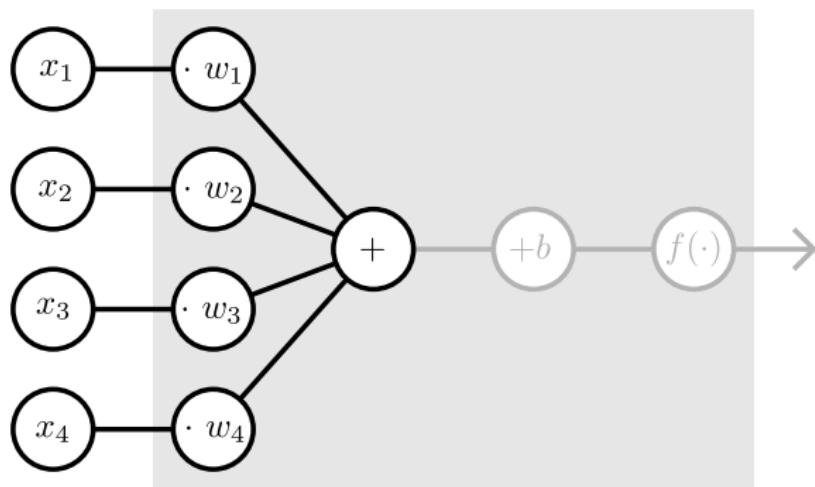
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



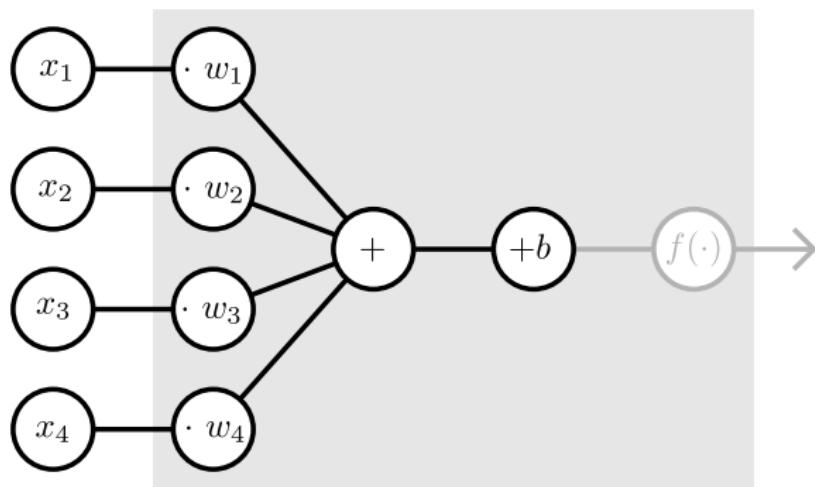
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



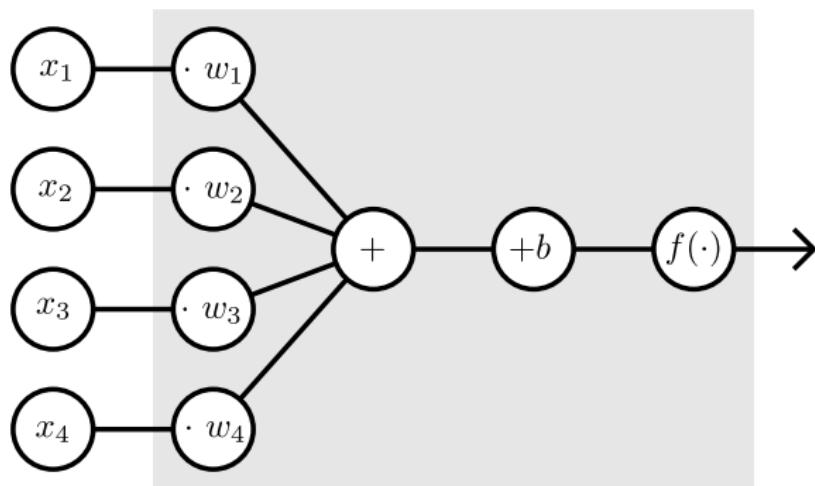
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



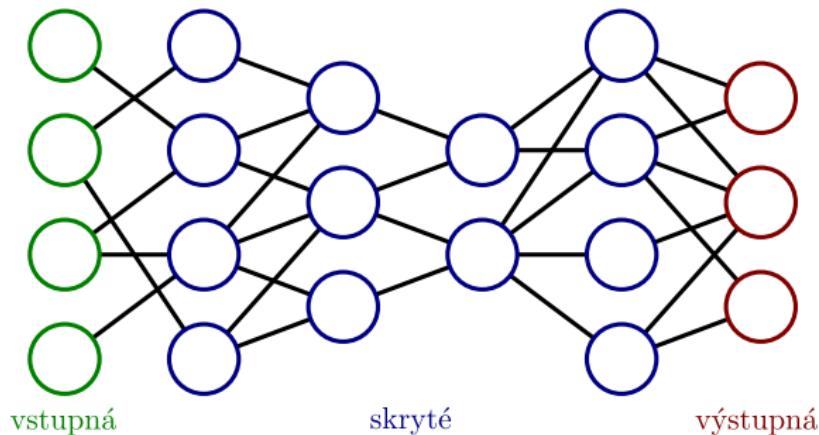
Umelý neurón

- ▶ parametrizovaná transformácia vstupov



Umelé neurónové siete

- ▶ skladanie sietí z umelých neurónov
- ▶ dopredné neurónové siete: neuróny organizované do vrstiev



Výpočtový graf

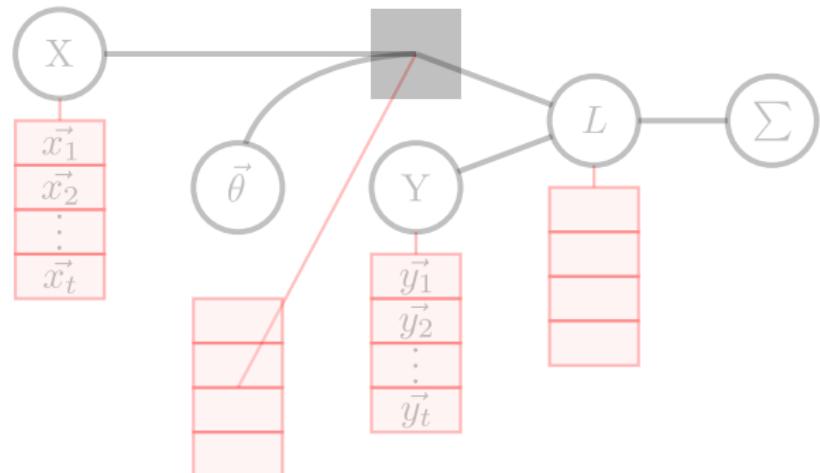
- ▶ orientovaný graf
- ▶ vrcholy reprezentujú aplikácie funkcií alebo hodnoty
- ▶ hrany reprezentujú vstupy do vrcholov
- ▶ operácie aj s vektormi a tenzormi

Učenie s učiteľom, všeobecne

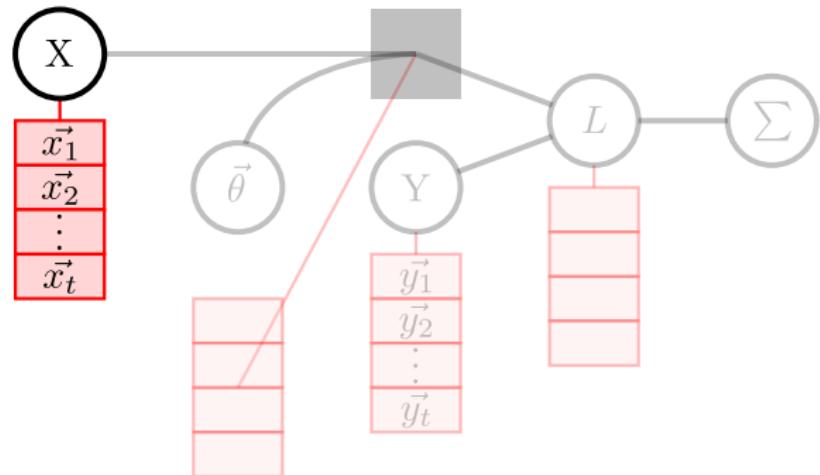
- ▶ trénovacie dátá: dvojice [vstup, správny výstup]
- ▶ minimalizujeme celkovú "chybu"

$$\sum_{i=1}^t L(\text{správny výstup}, \text{náš výstup})$$

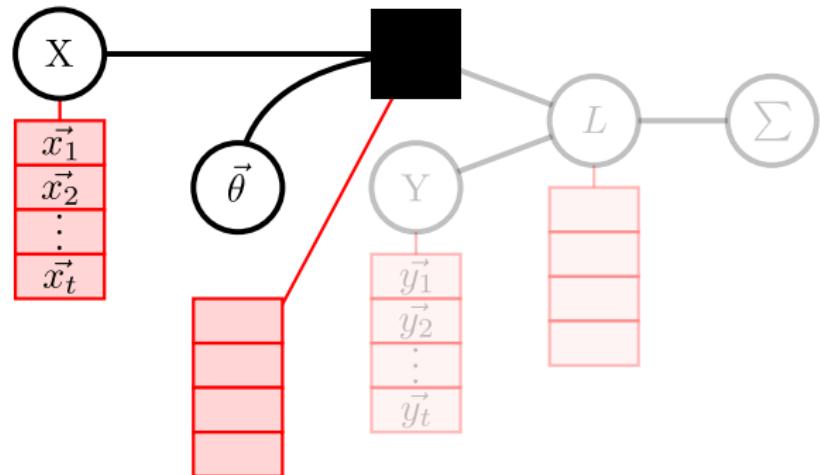
Učenie s učiteľom, výpočtový graf



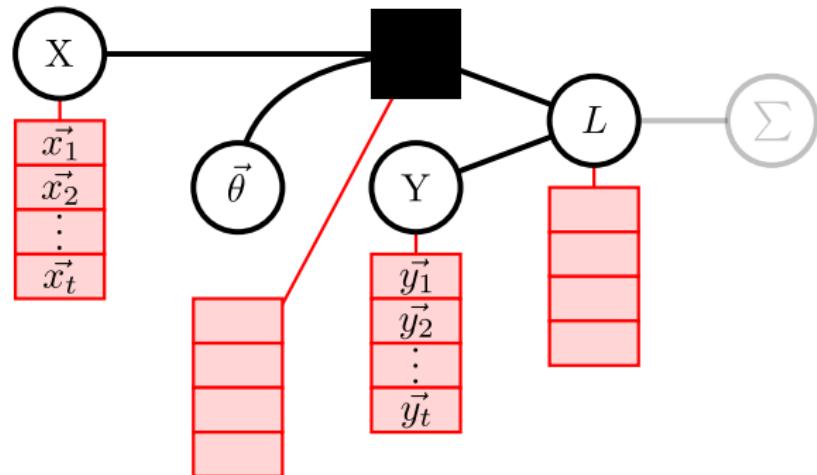
Učenie s učiteľom, výpočtový graf



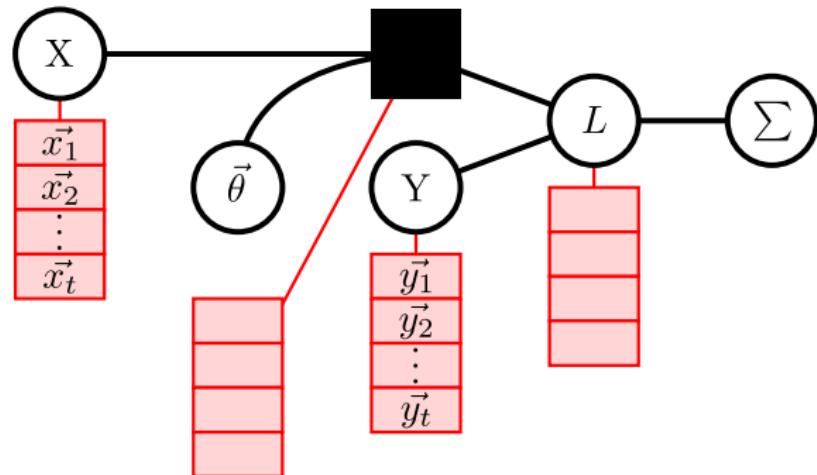
Učenie s učiteľom, výpočtový graf



Učenie s učiteľom, výpočtový graf



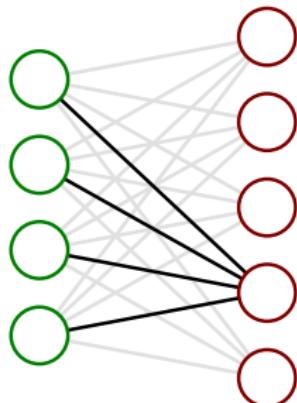
Učenie s učiteľom, výpočtový graf



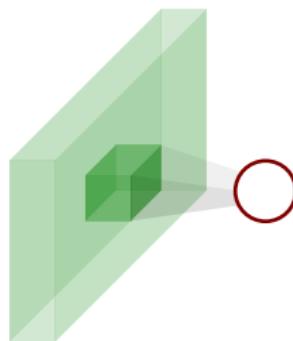
Učenie s učiteľom, výpočtový graf

- ▶ upravíme parametre siete podľa gradientu
- ▶ algoritmus späťnej propagácie chýb (angl. backpropagation)
- ▶ využitie tejto informácie—rôzne optimalizačné algoritmy

Štandardné stavebné prvky



Obr.: plne
prepojená vrstva



Obr.: konvolučná
vrstva

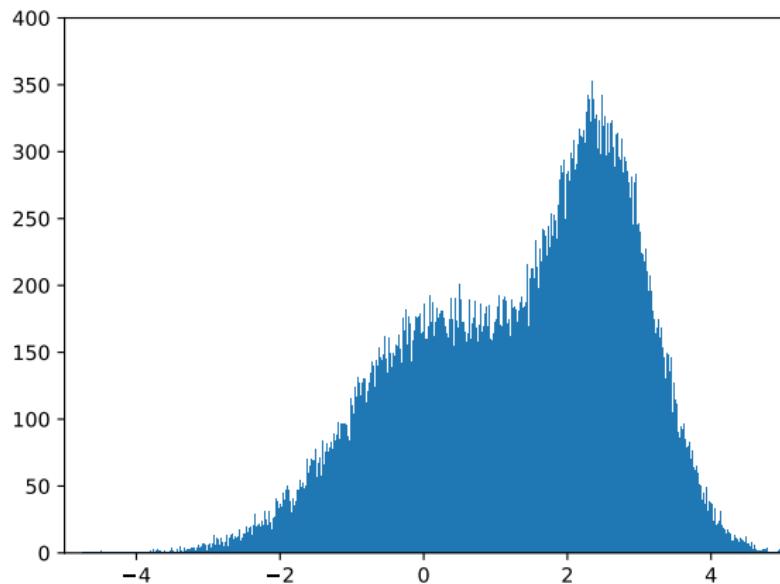
+ aktivačná vrstva

Ďalšie stavebné prvky

- ▶ dropout
- ▶ dávková normalizácia

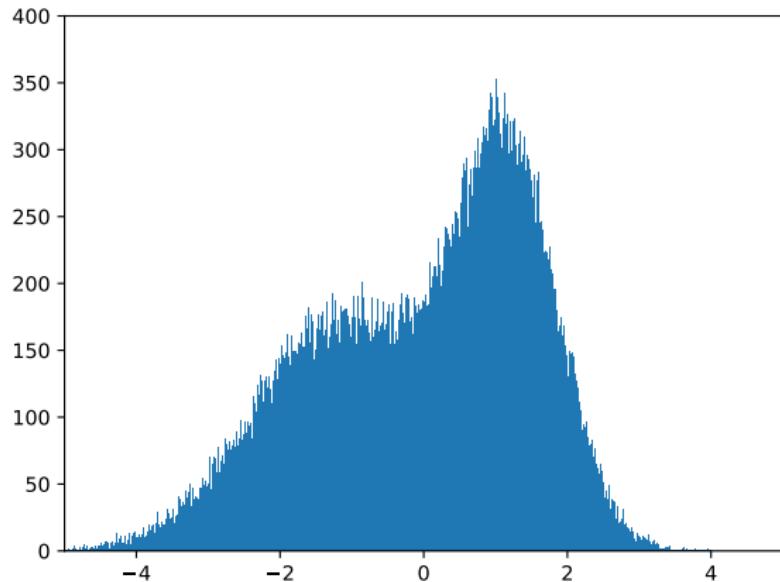
Dávková normalizácia

- ▶ $\text{Mean}(\vec{x}) = 0$
- ▶ $\text{Var}(\vec{x}) = 1$



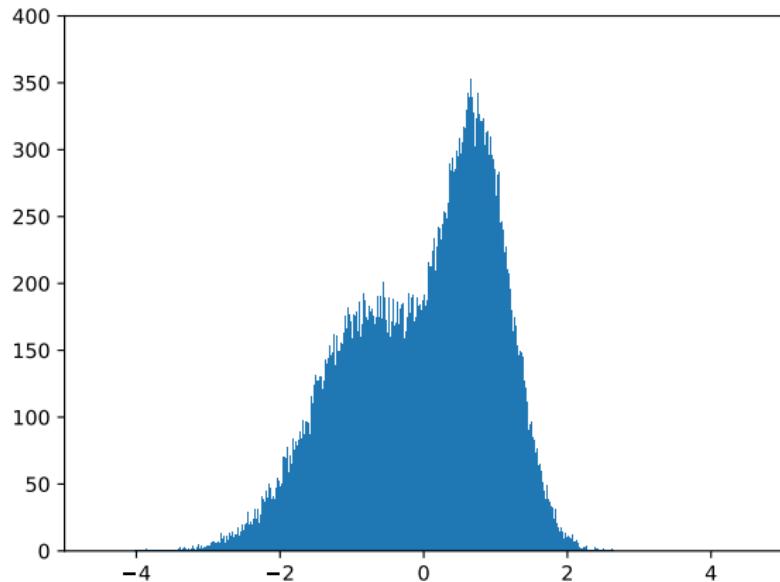
Dávková normalizácia

- ▶ $\text{Mean}(\vec{x}) = 0$
- ▶ $\text{Var}(\vec{x}) = 1$



Dávková normalizácia

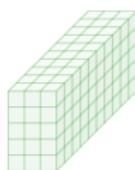
- ▶ $\text{Mean}(\vec{x}) = 0$
- ▶ $\text{Var}(\vec{x}) = 1$



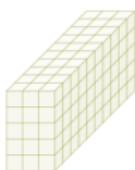
Navrhované vylepšenia

Posuvná vrstva

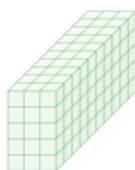
- ▶ pripočíta ku vstupom konštanty
- ▶ rôznym vstupom môže pripočítať rôzne, ale aj tie isté konštanty
 - ▶ posúvanie po prvkoch
 - ▶ po kanáloch
 - ▶ po vrstvách



+



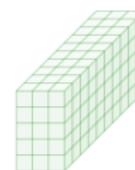
individuálne



+



kanálové



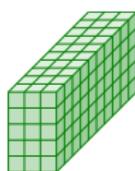
+



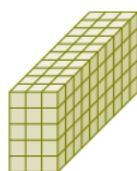
vrstvové

Posuvná vrstva

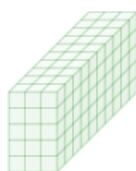
- ▶ pripočíta ku vstupom konštanty
- ▶ rôznym vstupom môže pripočítať rôzne, ale aj tie isté konštanty
 - ▶ posúvanie po prvkoch
 - ▶ po kanáloch
 - ▶ po vrstvách



+



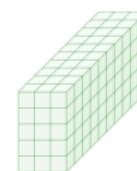
individuálne



+



kanálové



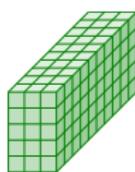
+



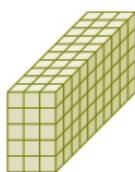
vrstvové

Posuvná vrstva

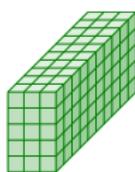
- ▶ pripočíta ku vstupom konštanty
- ▶ rôznym vstupom môže pripočítať rôzne, ale aj tie isté konštanty
 - ▶ posúvanie po prvkoch
 - ▶ po kanáloch
 - ▶ po vrstvách



+



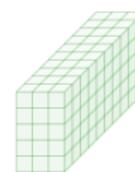
individuálne



+



kanálové



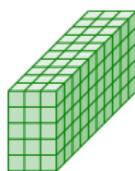
+



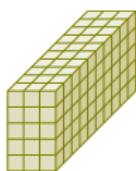
vrstvové

Posuvná vrstva

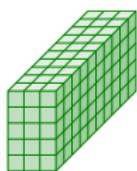
- ▶ pripočíta ku vstupom konštanty
- ▶ rôznym vstupom môže pripočítať rôzne, ale aj tie isté konštanty
 - ▶ posúvanie po prvkoch
 - ▶ po kanáloch
 - ▶ po vrstvách



+



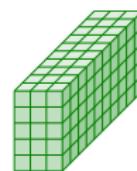
individuálne



+



kanálové



+



vrstvové

Škálovacia vrstva

- ▶ vynásobí vstupy konštantami
- ▶ rôzne vstupy môže vynásobiť rôznymi ale aj tými istými konštantami

Pozmenenie architektúry

- ▶ Za vstupnou vrstvou a za každou aktivačnou vrstvou, okrem poslednej:
 - ▶ (posuvná vrstva)
 - ▶ (škálovacia vrstva)

Testované kombinácie

		škálovanie			
		žiadne	individuálne	kanálové	vrstvové
posúvanie	žiadne	✓	✓	✓	✓
	individuálne	✓	✓	✗	✗
	kanálové	✓	✗	✓	✗
	vrstvové	✓	✗	✗	✓

Experimenty

Ako porovnávať?

- ▶ trénovacia chyba
- ▶ chyba na dátach, ktoré neboli použité pri trénovaní—**valídačná chyba**
- ▶ (presnosť klasifikácie)

Vylepšenia

- ▶ žiadne
- ▶ s dávkovou normalizáciou
- ▶ naše

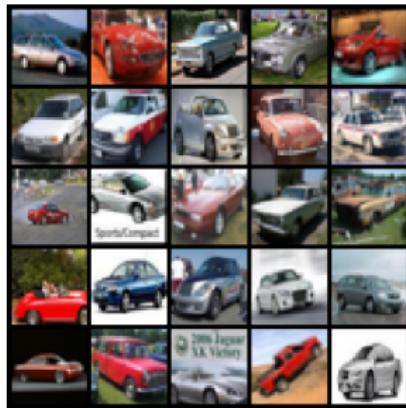
Dáta

- ▶ CIFAR10, CIFAR100
- ▶ 32×32 RGB obrázky, 10 resp. 100 tried
- ▶ 50 000 trénovacích, 10 000 testovacích dát
- ▶ vstupy normalizované

Dáta



(a) lietadlá



(b) autá

Obr.: Dve triedy z CIFAR10

Architektúry

- ▶ úplne konvolučná siet'
- ▶ viacvrstvový perceptrón

Dve verzie: s dropoutom/bez dropoutu

Technické detaily 1

- ▶ výstupná vrstva má 10 (resp. 100) neurónov
- ▶ posledná aktivačná funkcia je softmax, ostatné sú ReLU
- ▶ chybová funkcia: cross-entropy
- ▶ optimalizačný algoritmus: stochastická metóda najstrmšieho spádu, momentum 0.9

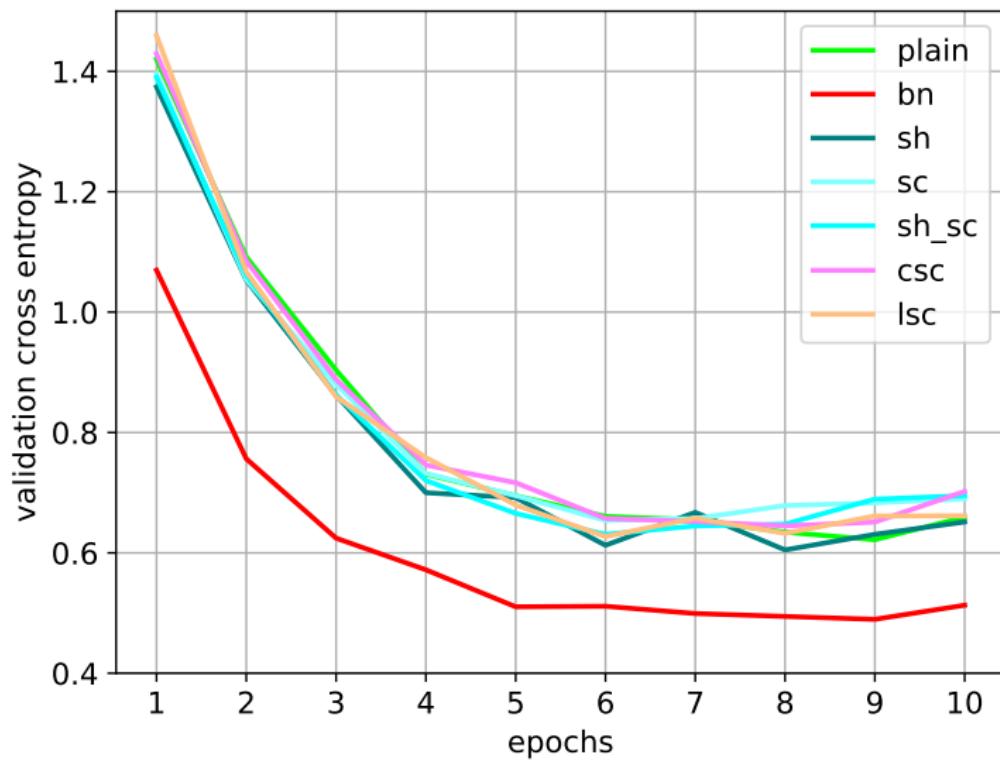
Technické detaľy 2

- ▶ inicializácia váh: He inicializácia, rovnaká inicializácia pre rôzne vylepšenia
- ▶ +– manuálne hľadanie rýchlosťi učenia (na grid search málo výpočtového času/sily)
- ▶ implementované vo frameworku PyTorch
- ▶ Microsoft Azure data science, 4 grafické karty

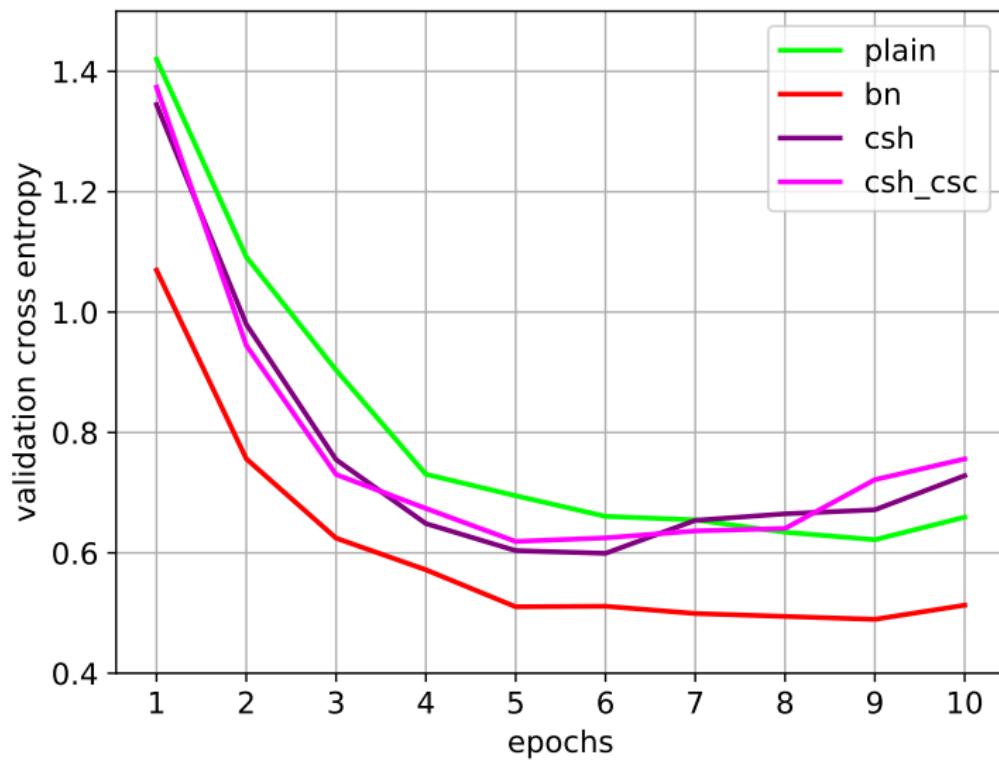
Počiatočný experiment

- ▶ CIFAR10
- ▶ úplne konvolučná sieť, bez dropoutu
- ▶ skúšame všetky vylepšenia

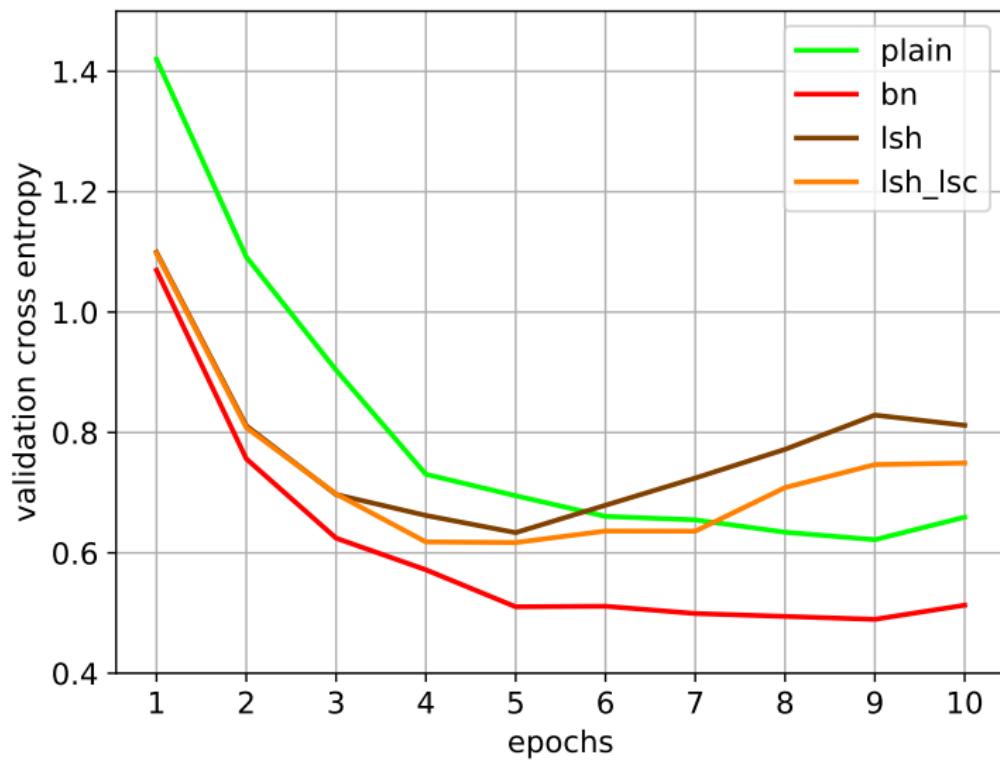
Počiatočný experiment



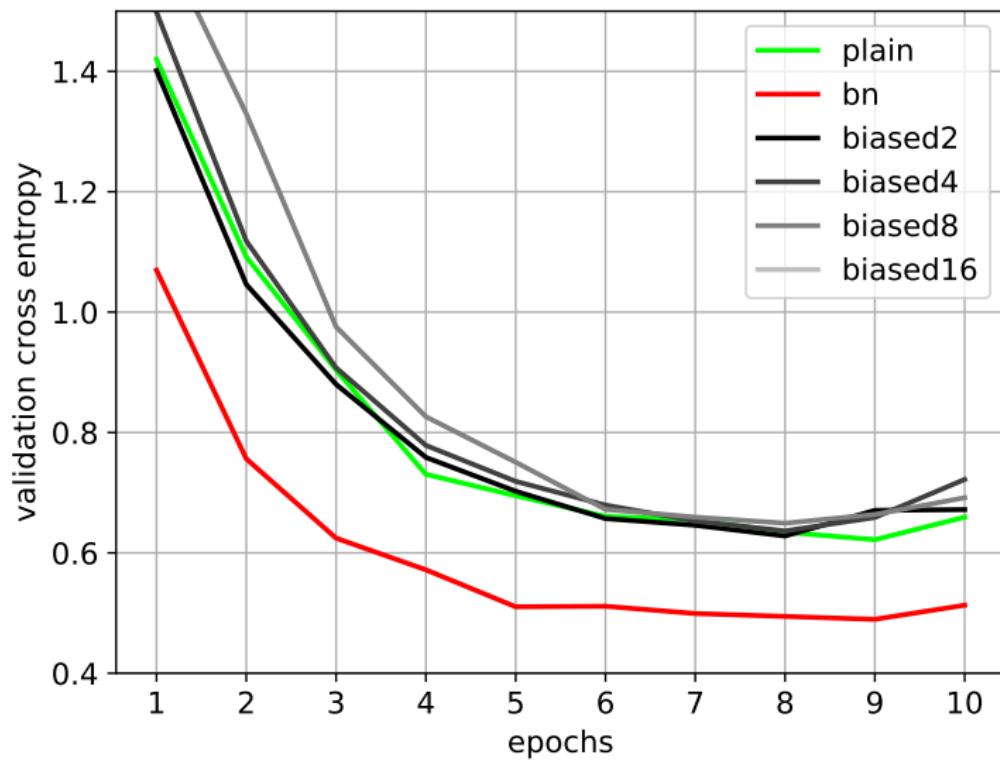
Počiatočný experiment



Počiatočný experiment



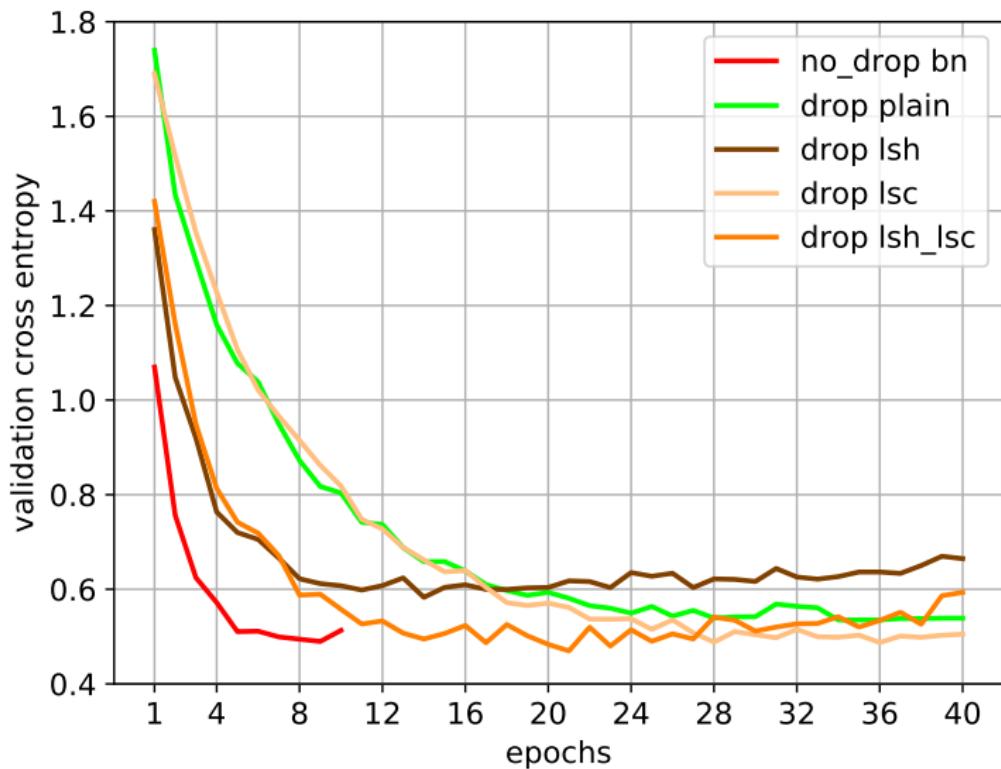
Počiatočný experiment



Experiment 2: dropout

- ▶ s dropoutom
- ▶ z našich skúšame len vrstvové kombinácie
- ▶ (CIFAR10, úplne konvolučná sieť)

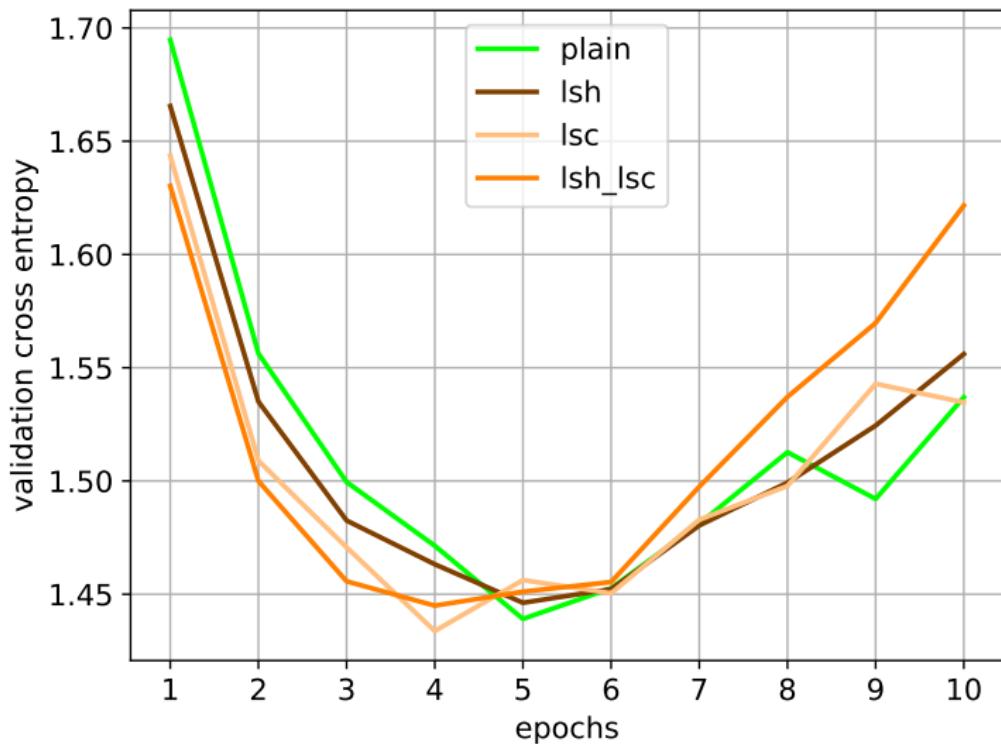
Experiment 2: dropout



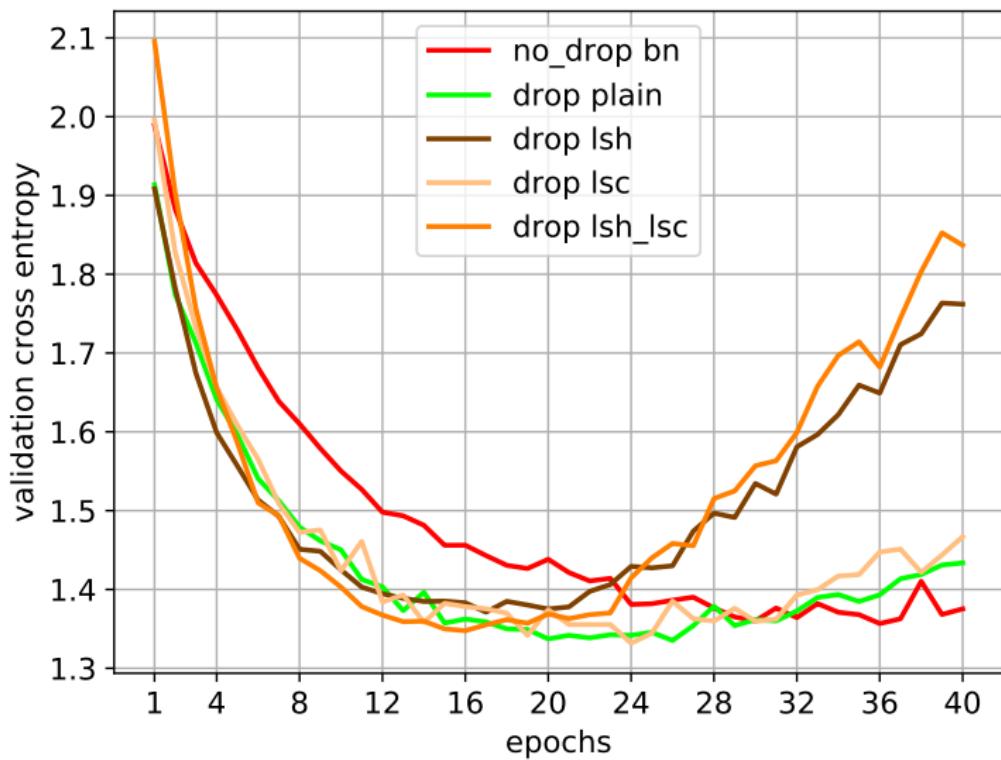
Experimenty 3 a 4: iná architektúra

- ▶ viacvrstvový perceptrón, najprv bez dropoutu a potom s dropoutom
- ▶ (CIFAR10, skúšame len vrstvové kombinácie)

Experiment 3



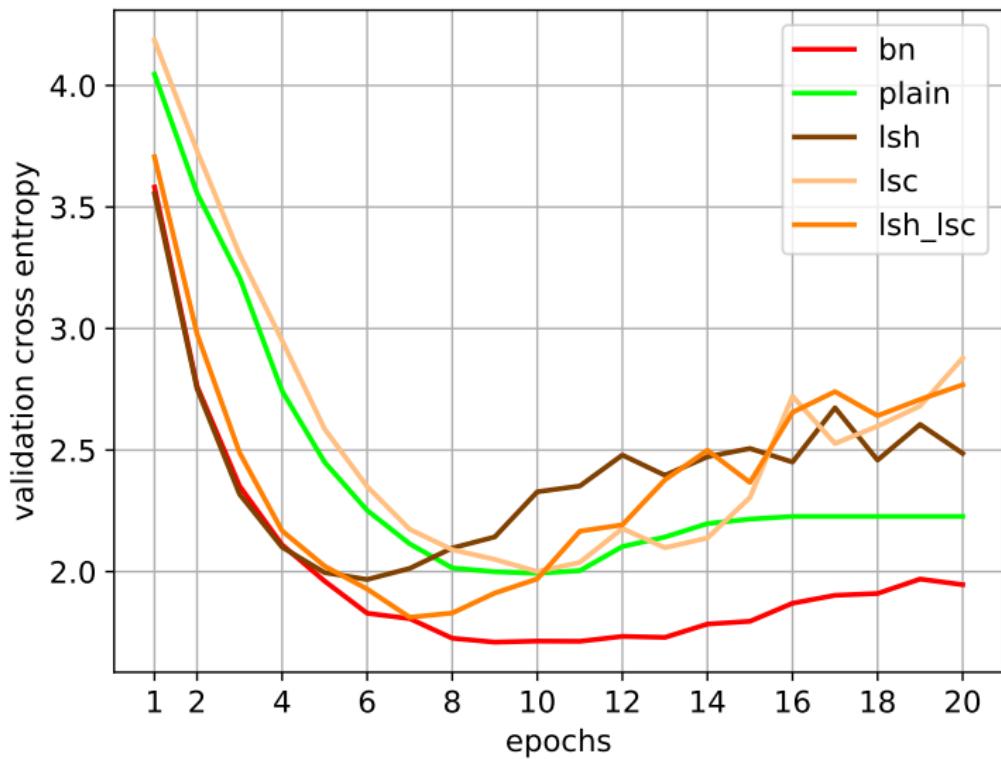
Experiment 4



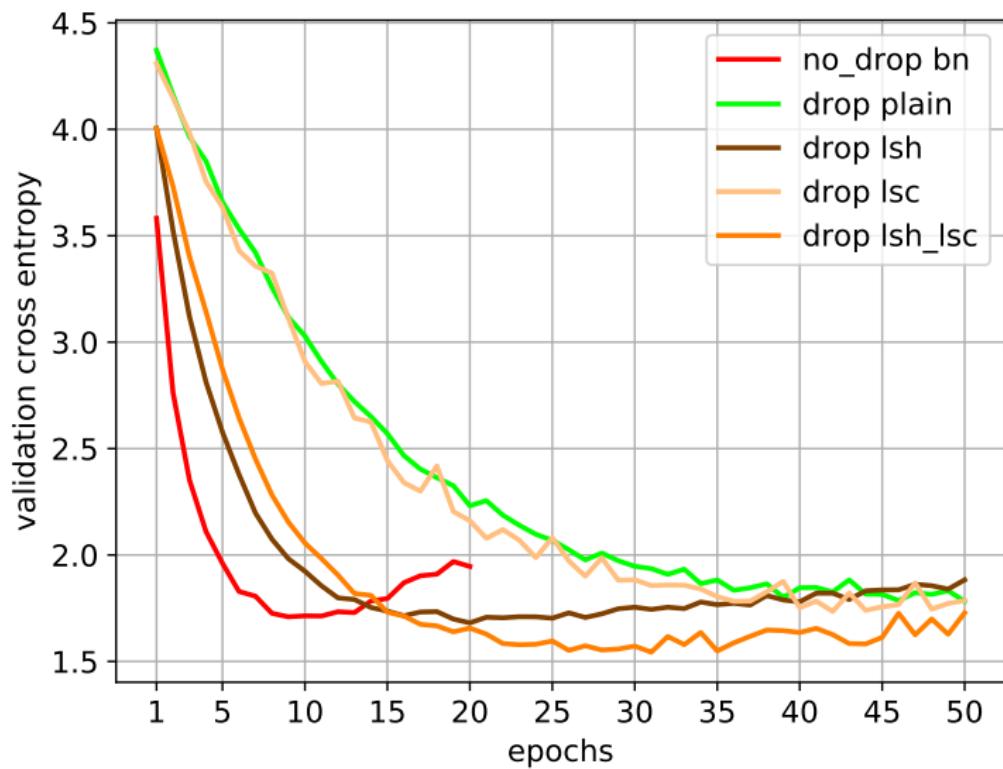
Experimenty 5 a 6: iný dataset

- ▶ CIFAR100
- ▶ úplne konvolučná sieť, najprv bez dropoutu a potom s dropoutom
- ▶ (skúšame len vrstvové kombinácie)

Experiment 5



Experiment 6



Záver

Zhrnutie experimentov

- ▶ vrstvové posúvanie-aj-škálovanie je najlepšia kombinácia
- ▶ lepšie ako žiadne vylepšenie, ale tendencia sa preučiť
- ▶ neporazili sme dávkovú normalizáciu, ale tá sa nie vždy dá použiť (online learning)

Ďalšia práca

- ▶ dôvod pozorovaného urýchlenia?
- ▶ čo sa naše vrstvy reálne naučia?
- ▶ vyhodnotiť na veľkých architektúrach

Otázky školiteľa

Otázka 1

Akým spôsobom ste vyberali experimentálne parametre? Napríklad pre parameter rýchlosť učenia ste testovali iba 3 hodnoty (0.02, 0.04 a 0.08) - prečo?.

Odpoved' 1

- ▶ relatívny rozdiel rýchlosťi učenia, nie absolútny
- ▶ málo otestovaných hodnôt ← málo výpočtového času
- ▶ experimentálne parametre:
 - ▶ architektúra
 - ▶ (chybová funkcia)
 - ▶ regularizácia

Otázka 1

Akým spôsobom ste vyberali experimentálne parametre? Napríklad pre parameter rýchlosť učenia ste testovali iba 3 hodnoty (0.02, 0.04 a 0.08) - prečo?.

Odpoved' 1

- ▶ relatívny rozdiel rýchlosťi učenia, nie absolútny
- ▶ málo otestovaných hodnôt ← málo výpočtového času
- ▶ experimentálne parametre:
 - ▶ architektúra
 - ▶ (chybová funkcia)
 - ▶ regularizácia

Otázka 1

Akým spôsobom ste vyberali experimentálne parametre? Napríklad pre parameter rýchlosť učenia ste testovali iba 3 hodnoty (0.02, 0.04 a 0.08) - prečo?.

Odpoved' 1

- ▶ relatívny rozdiel rýchlosťi učenia, nie absolútny
- ▶ málo otestovaných hodnôt ← málo výpočtového času
- ▶ experimentálne parametre:
 - ▶ architektúra
 - ▶ (chybová funkcia)
 - ▶ regularizácia

Otázka 1

Akým spôsobom ste vyberali experimentálne parametre? Napríklad pre parameter rýchlosť učenia ste testovali iba 3 hodnoty (0.02, 0.04 a 0.08) - prečo?.

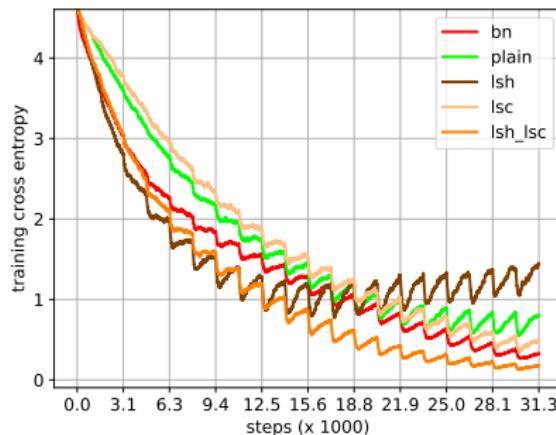
Odpoved' 1

- ▶ relatívny rozdiel rýchlosťi učenia, nie absolútny
- ▶ málo otestovaných hodnôt ← málo výpočtového času
- ▶ experimentálne parametre:
 - ▶ architektúra
 - ▶ (chybová funkcia)
 - ▶ regularizácia

Otázky oponenta

Otázka 1

Vysvetlite dôvod pílovitého priebehu poklesu chyby v grafoch.
Koefficient 0.99 nie je vysvetlený.



Obr.: (CIFAR100, úplne konvolučná siet bez dropoutu.) Exponential moving average of training errors after each step, with coefficient 0.99.

Ďalšie otázky

- ▶ Z práce nie je jasné, ako ste hľadali optimálne hodnoty posunu a škálovania (kap. 5) v jednotlivých modeloch. Pomocou gradientu (t.j. analogicky k synaptickým váham)?
- ▶ Neskúmali ste skonvergované hodnoty posunu a škálovania aktivít pre jednotlivé behy (s rovnakým seedom)? Boli podobné?
- ▶ V závere píšete, že použitie layerwise shift/scale metódy je sľubné, pretože výrazne urýchluje učenie, no s rizikom preučenia. Ako by ste DNN nanutili silnejšiu regularizáciu?

Ďalšie otázky

- ▶ Z práce nie je jasné, ako ste hľadali optimálne hodnoty posunu a škálovania (kap. 5) v jednotlivých modeloch. Pomocou gradientu (t.j. analogicky k synaptickým váham)?
- ▶ Neskúmali ste skonvergované hodnoty posunu a škálovania aktivít pre jednotlivé behy (s rovnakým seedom)? Boli podobné?
- ▶ V závere píšete, že použitie layerwise shift/scale metódy je slibné, pretože výrazne urýchluje učenie, no s rizikom preučenia. Ako by ste DNN nanutili silnejšiu regularizáciu?

Ďalšie otázky

- ▶ Z práce nie je jasné, ako ste hľadali optimálne hodnoty posunu a škálovania (kap. 5) v jednotlivých modeloch. Pomocou gradientu (t.j. analogicky k synaptickým váham)?
- ▶ Neskúmali ste skonvergované hodnoty posunu a škálovania aktivít pre jednotlivé behy (s rovnakým seedom)? Boli podobné?
- ▶ V závere píšete, že použitie layerwise shift/scale metódy je sľubné, pretože výrazne urýchľuje učenie, no s rizikom preučenia. Ako by ste DNN nanutili silnejšiu regularizáciu?