

Spájanie neurónových sietí

Školiteľ: Vladimír Boža

Žiak: Martin Pašen

Typická situácia v strojovom učení

- Úloha a dataset
 - klasifikácia, regresia, ...
 - Dataset je množina párov (\vec{x}_i, y_i^*)

Typická situácia v strojovom učení

- Úloha a dataset
 - klasifikácia, regresia, ...
 - Dataset je množina párov (\vec{x}_i, y_i^*)
- Trieda hypotéz
 - rozhodovací strom, lineárna regresia, neurónová sieť, ...
 - $M(\vec{x}, \vec{w}) = y$



Typická situácia v strojovom učení

- Úloha a dataset
 - klasifikácia, regresia, ...
 - Dataset je množina párov (\vec{x}_i, y_i^*)
- Trieda hypotéz
 - rozhodovací strom, lineárna regresia, neurónová sieť, ...
 - $M(\vec{x}, \vec{w}) = y$
- Chybová funkcia
 - kvadratická chyba, vierohodnosť, ...
 - $E(\vec{w}, D) = e$

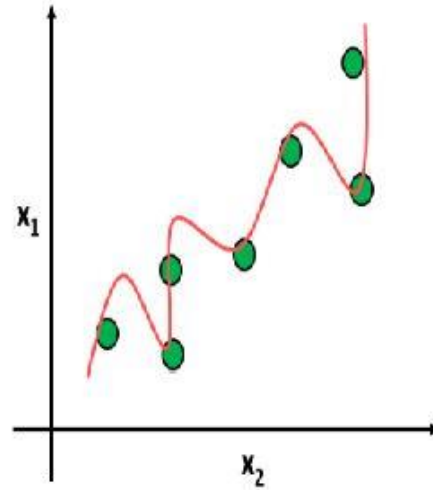

Typická situácia v strojovom učení

- Úloha a dataset
 - klasifikácia, regresia, ...
 - Dataset je množina párov (\vec{x}_i, y_i^*)
- Trieda hypotéz
 - rozhodovací strom, lineárna regresia, neurónová sieť, ...
 - $M(\vec{x}, \vec{w}) = y$
- Chybová funkcia
 - kvadratická chyba, vierohodnosť, ...
 - $E(\vec{w}, D) = e$
- Cieľ
 - Minimalizovať e
 - $\vec{w}_{i+1} = \vec{w}_i - \nabla_{\vec{w}_i}(e)$

Regularizácia



Regularizácia



$$e = E(\vec{w}, D)$$





$$e = E(\vec{w}, D) + L(\vec{w})$$



$$e = E(\vec{w}, D) + \lambda * L(\vec{w})$$

Regularizácia




$$e = E(\vec{w}, D)$$



$$e = E(\vec{w}, D) + L(\vec{w})$$



$$e = E(\vec{w}, D) + \lambda * L(\vec{w})$$



Relaxovaná L_0 regularizácia

- Každéj váhe priradíme bránu g
 - Brána je náhodná premenná
 - Má hodnoty z intervalu $\langle 0,1 \rangle$
 - Penalizácia = pravdepodobnosť, že sa váha použije = $P[g > 0]$

Naša úloha

- Vstup
 - Dataset
 - Dva natrénované modely s rovnakou architektúrou (učitelia)
- Výstup
 - Čo najlepší model s rovnakou architektúrou (žiak)


Destilácia vedomostí a orezávanie

- Cieľom je zjednodušiť komplexný model, no zachovať jeho silu
 - Zmenšenie časových, energetických a priestorových požiadaviek
 - Boj proti pretrénovaniu (overfitting)
- Destilácia vedomostí
 - Učíme nového žiaka od začiatku čo najlepšie plniť úlohu a zároveň napodobňovať učiteľa
- Orezávanie
 - Vytvárame nový model modifikáciu aktuálneho
 - Orezávame nepodstatné časti

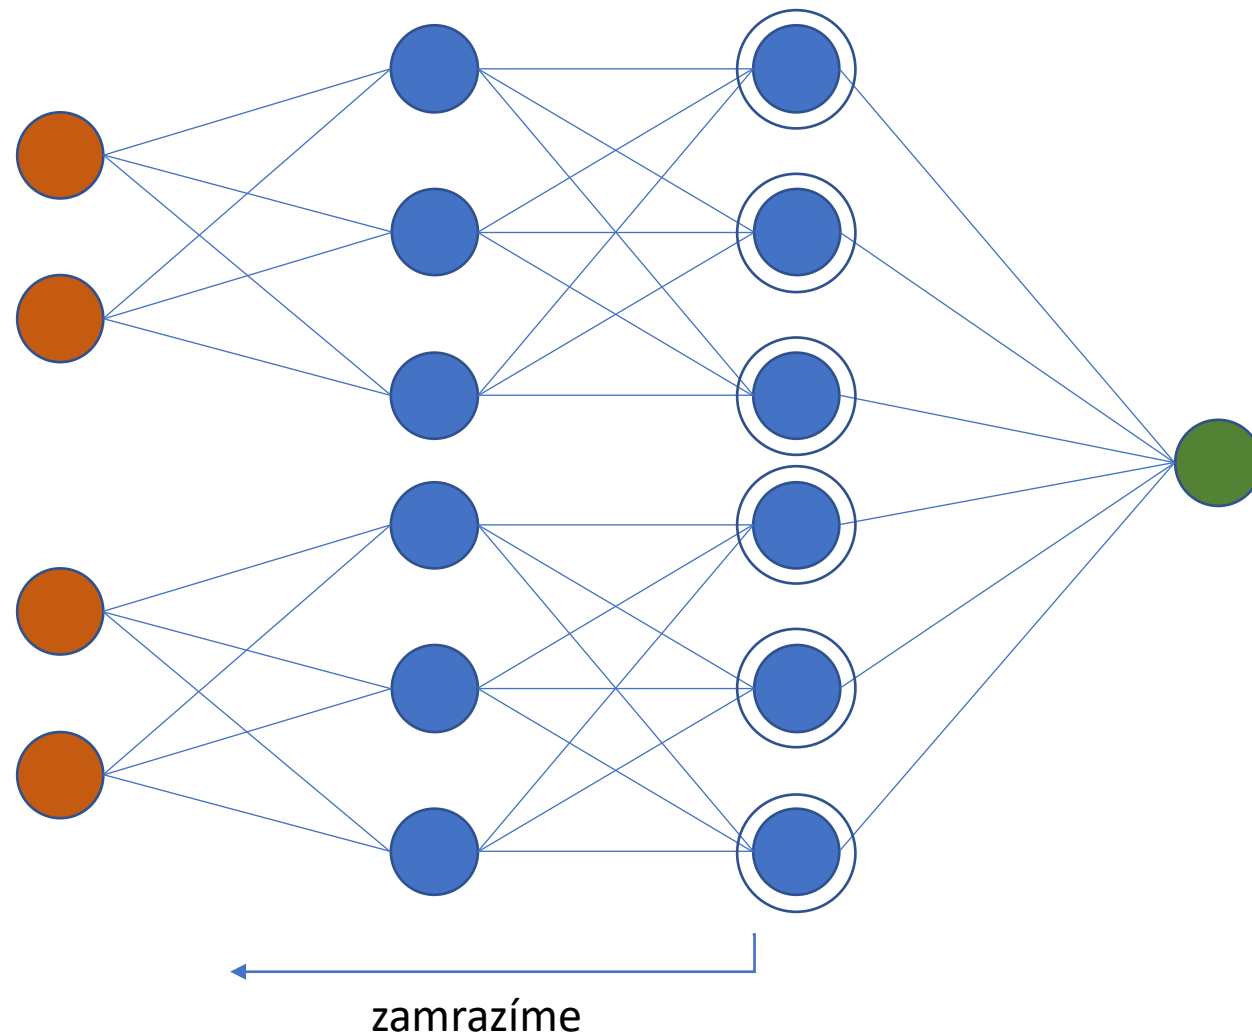
Prístup 1 – pažravý algoritmus

1. Zistíme dôležité časti učiteľov
2. Naučíme žiaka napodobňovať dôležité časti učiteľov
3. Dotrénujeme žiaka

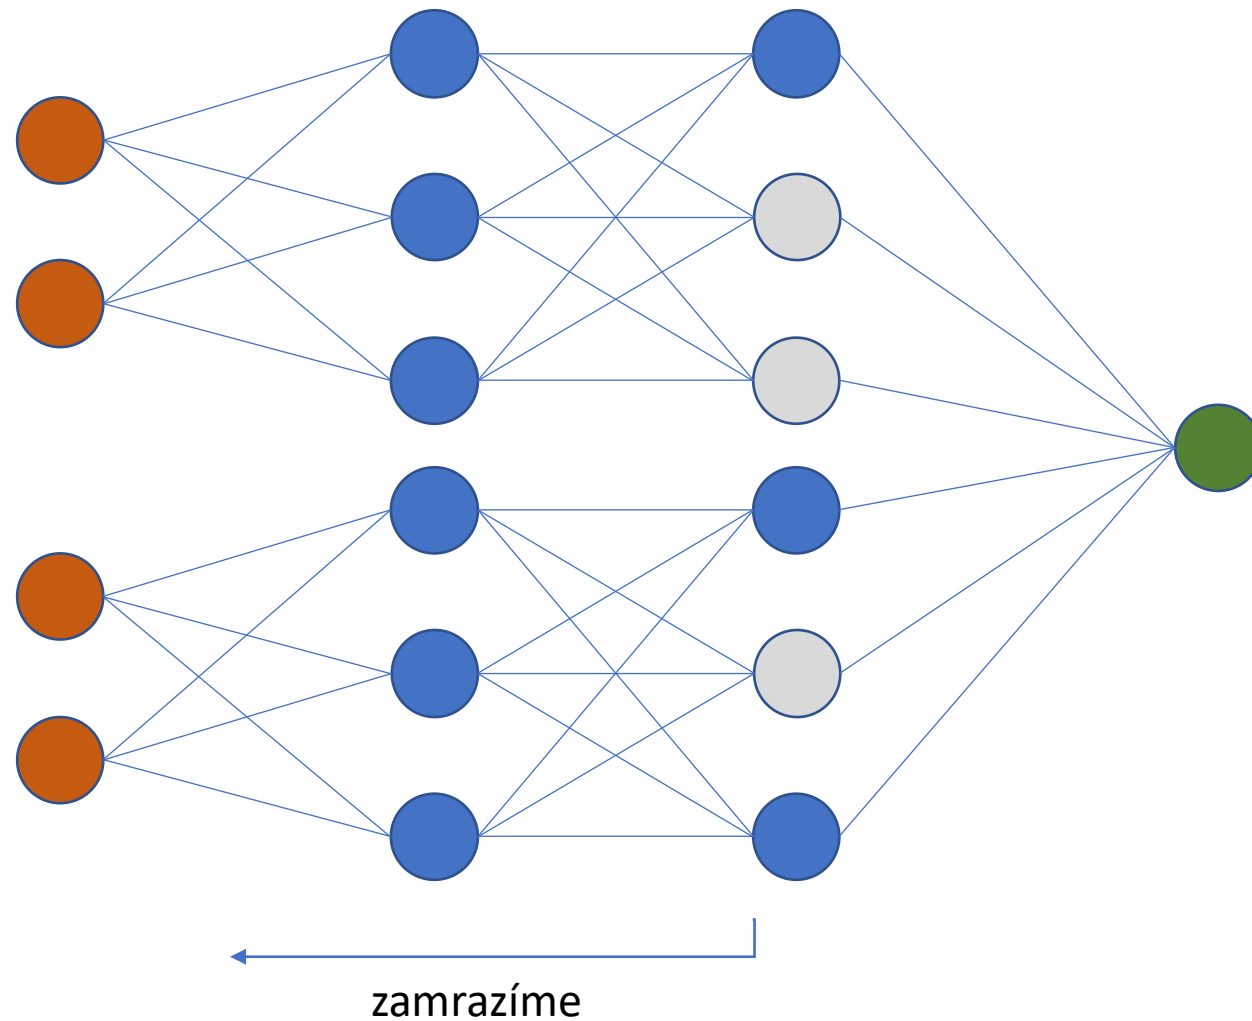
Pažravý algoritmus



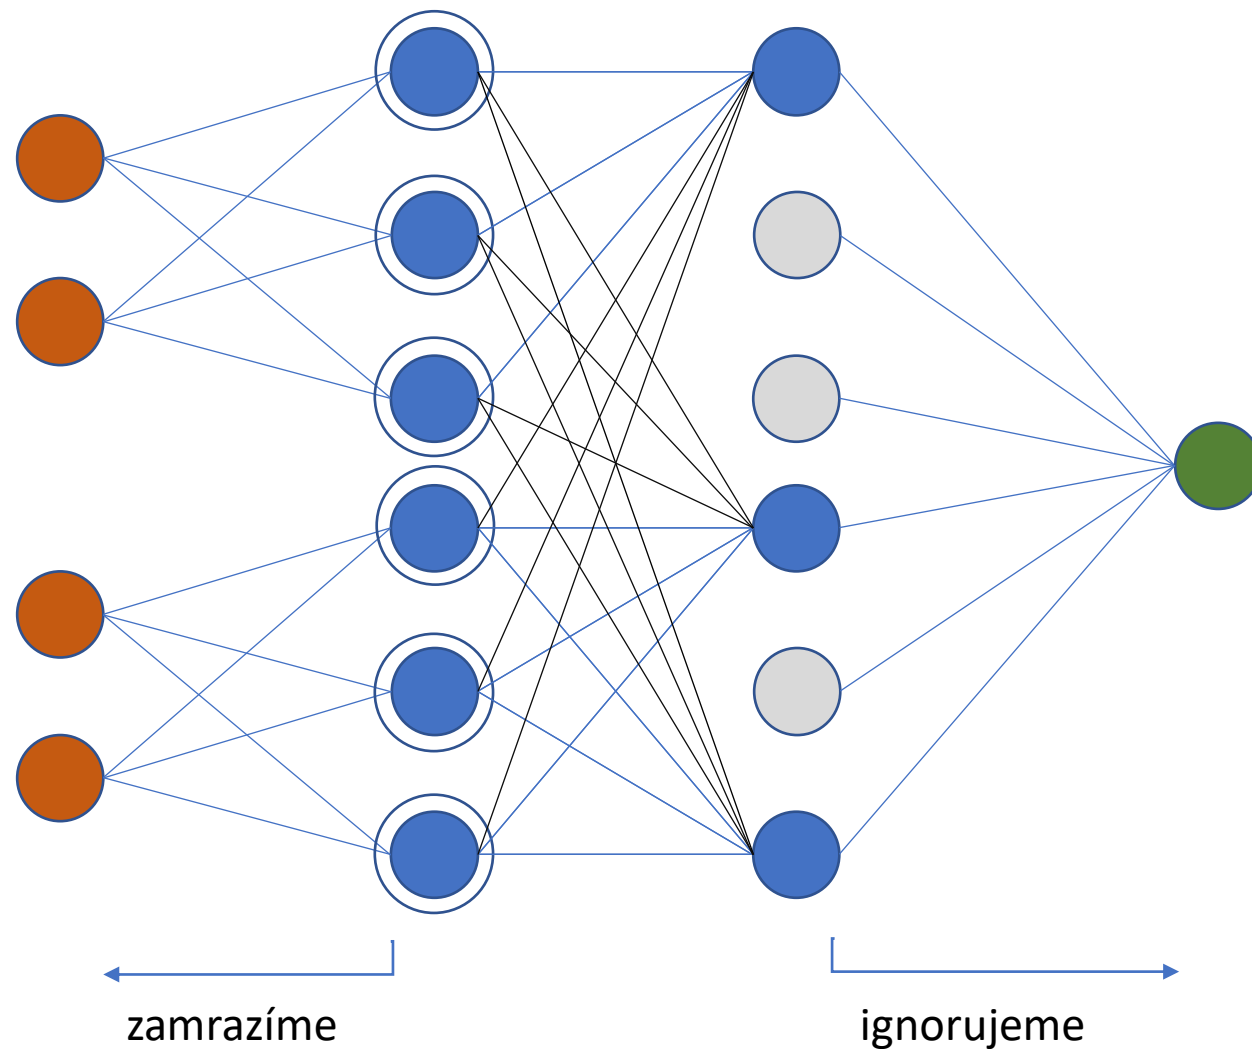
Pažravý algoritmus




Pažravý algoritmus



Pažravý algoritmus




Pažravý algoritmus




Prístup 2 – chybou motivovaný algoritmus

1. Spojíme učiteľov do jedného modelu
2. Trénujeme model aby čo najlepšie spĺňal úlohu, no zároveň používal len polovicu vrstiev
3. Orežeme nepodstatné časti
4. Dotrénujeme žiaka


Chybou motivovaný algoritmus




Chybou motivovaný algoritmus




Chybou motivovaný algoritmus



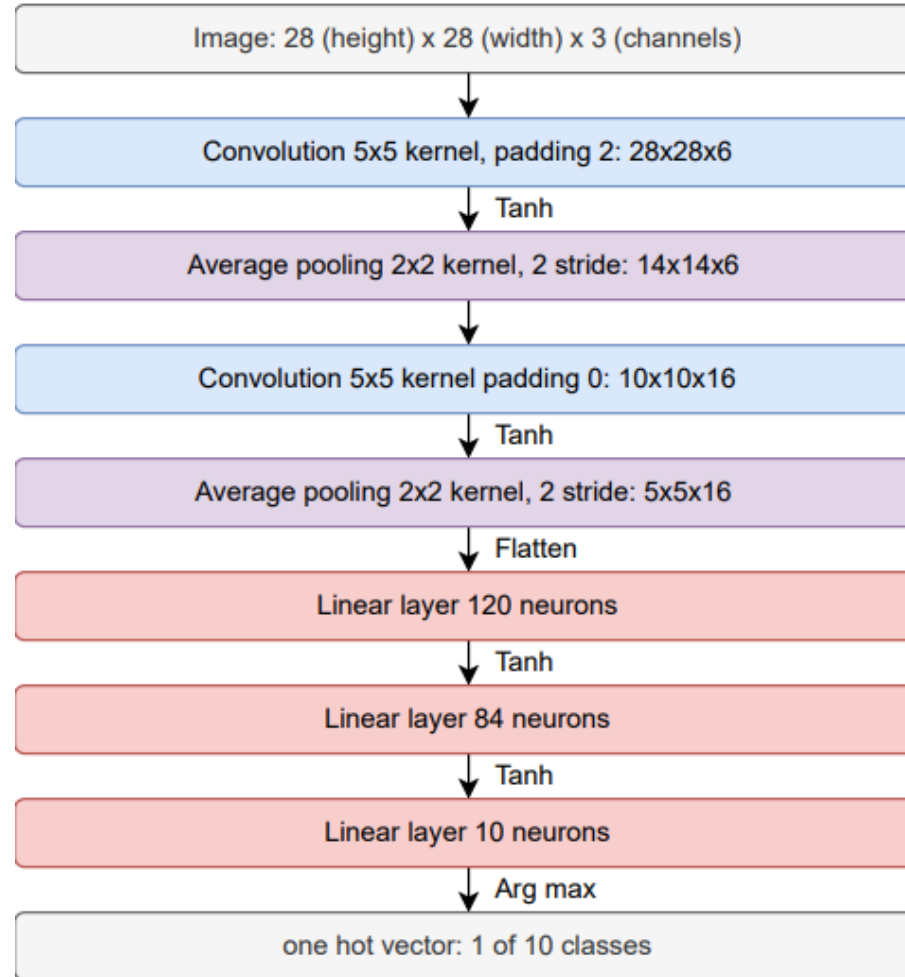
Chybou motivovaný algoritmus



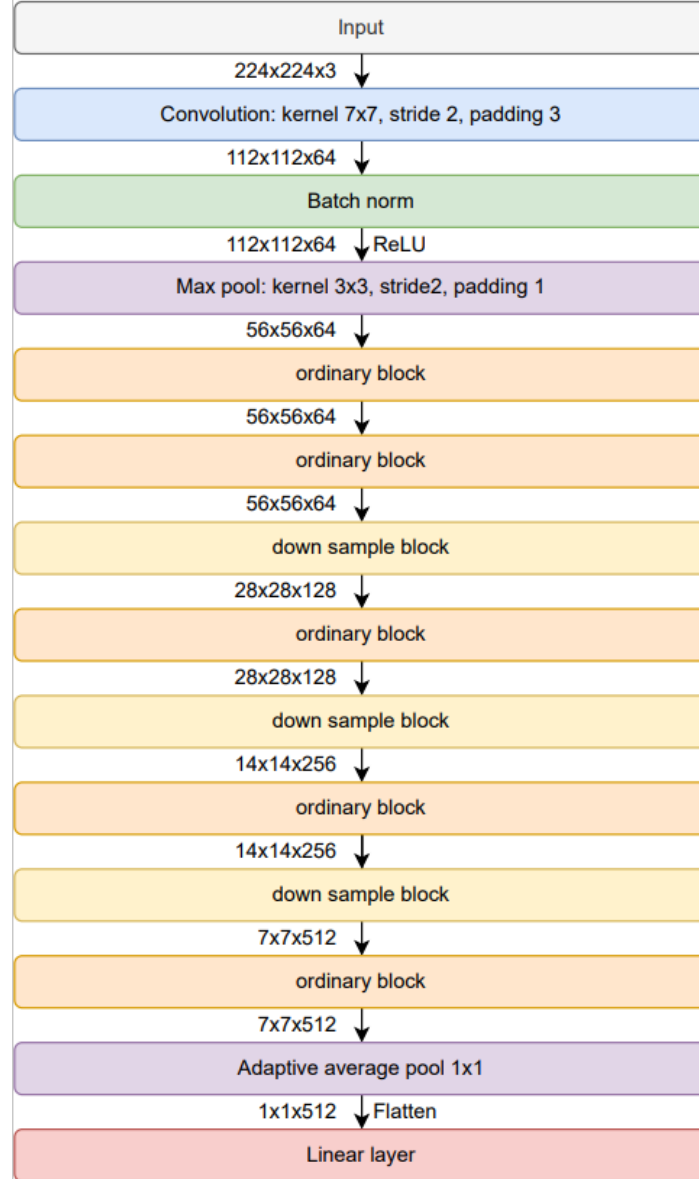
Chybou motivovaný algoritmus



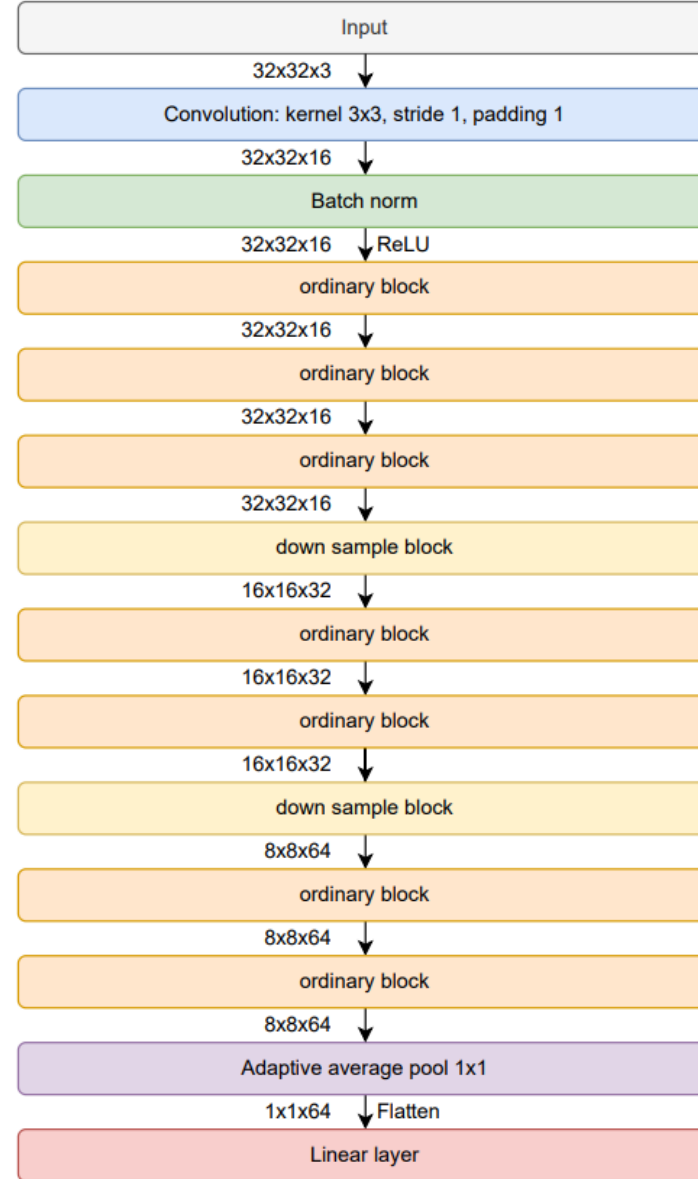
LeNet



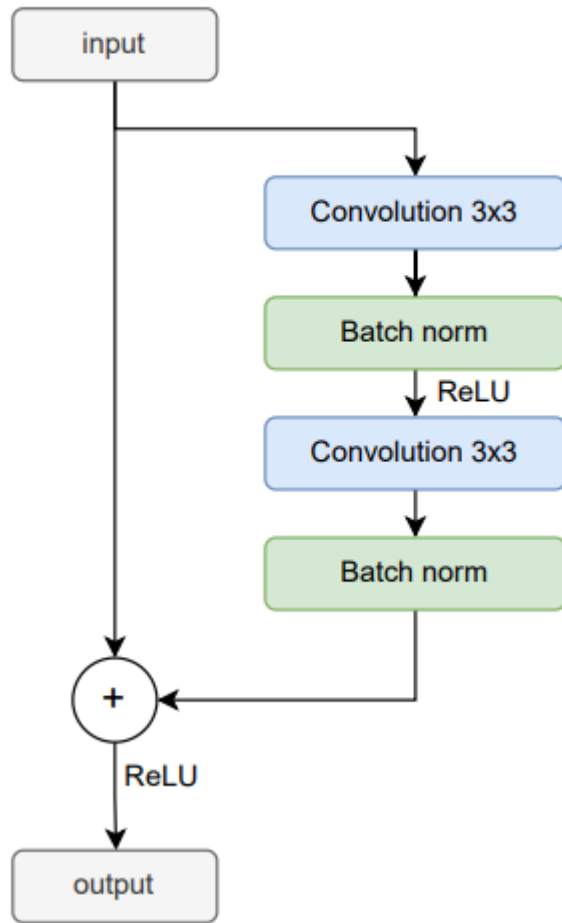
ResNet-18



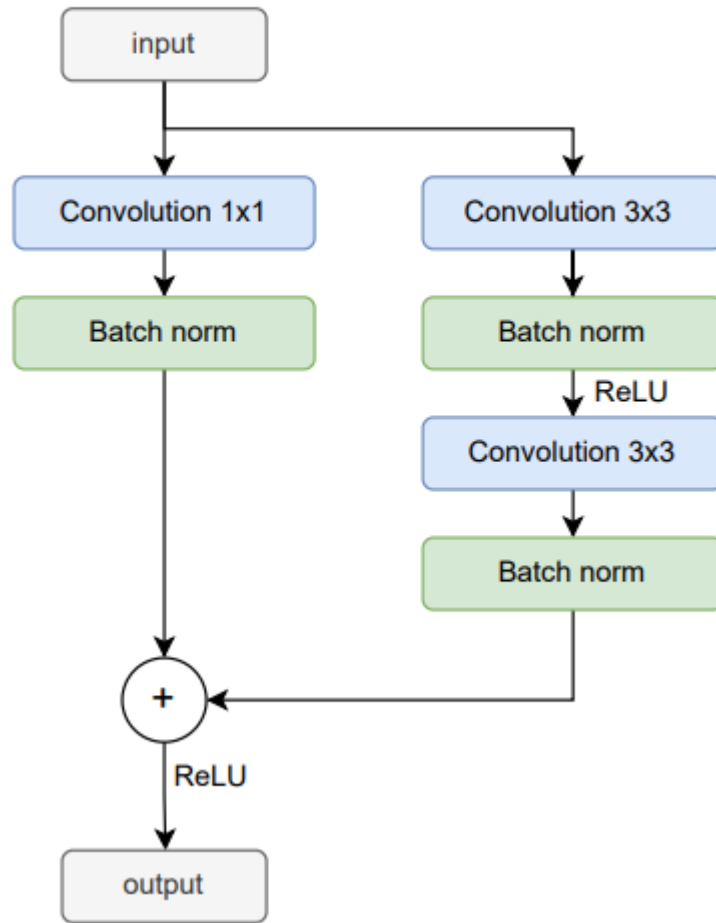
ResNet-20

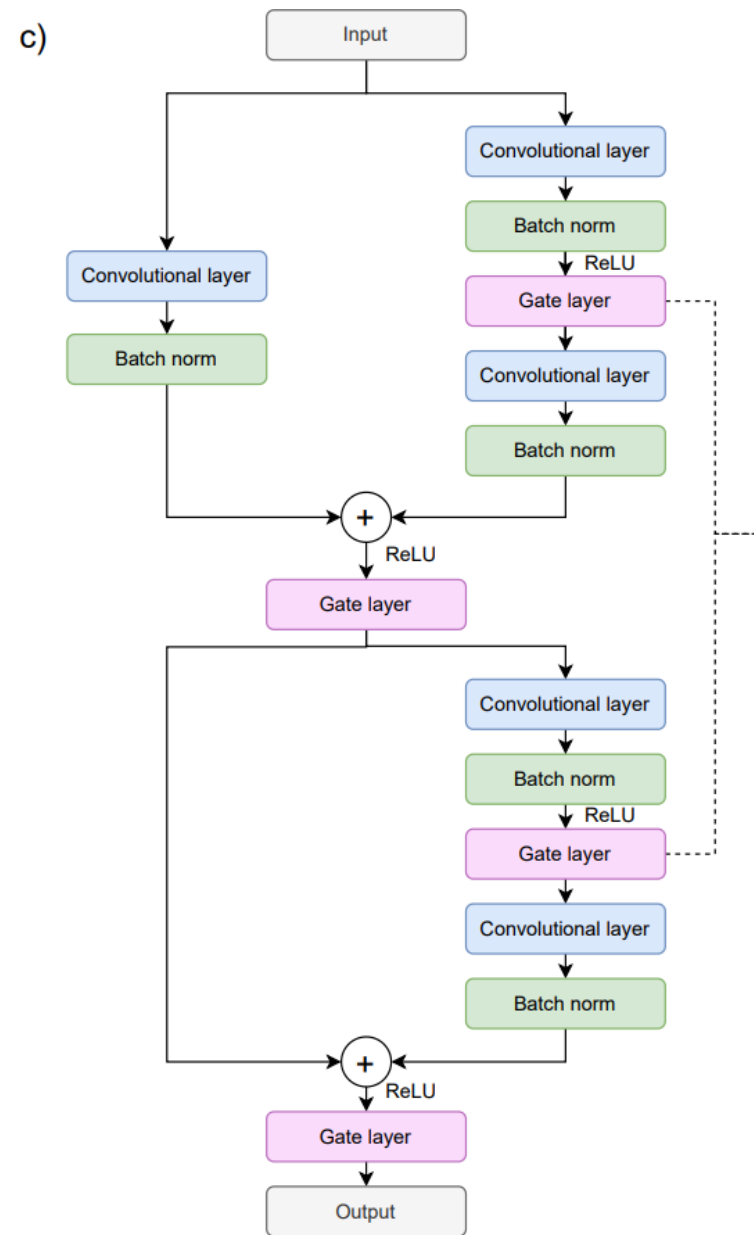
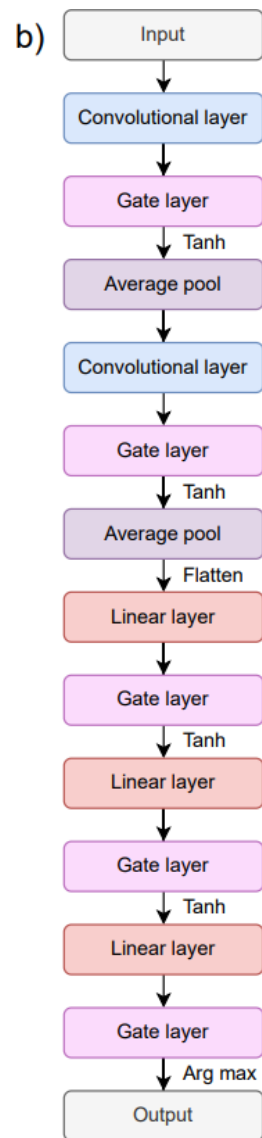



ordinary block



downsample block






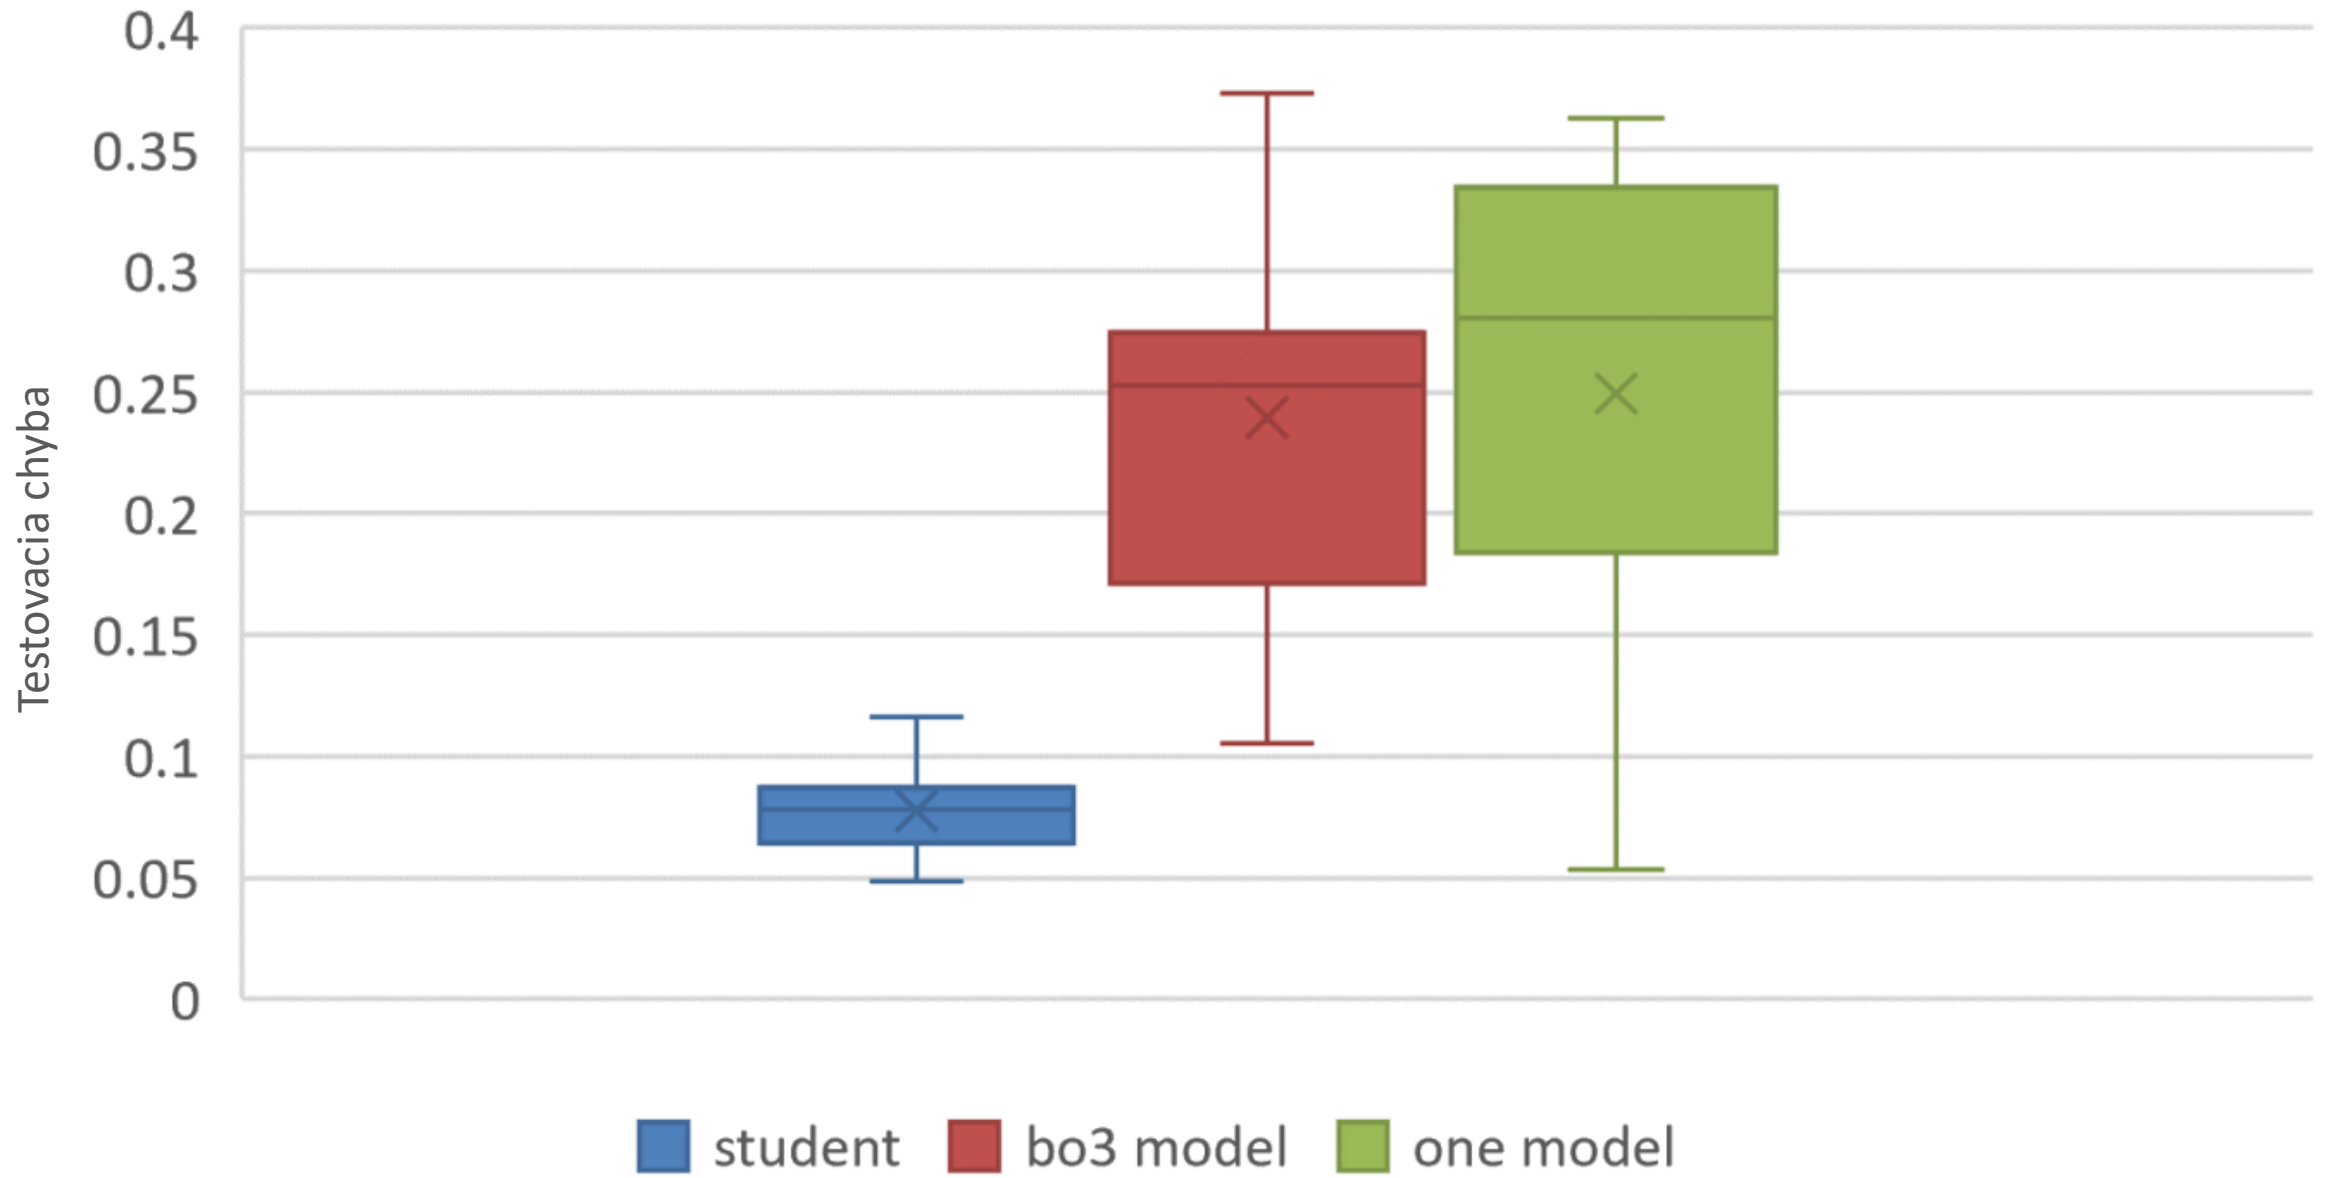
identické

Datasety a úlohy


- Skúšobný dataset
 - 5 vln sínusu so šumom
- Imagewoof
 - 10 plemien psov (13 000 obrázkov)
- Cifar 100
 - 100 kategórií (60 000 obrázkov)
- ImageNet
 - 1000 kategórií (1 300 000 obrázkov)




Sínus




student



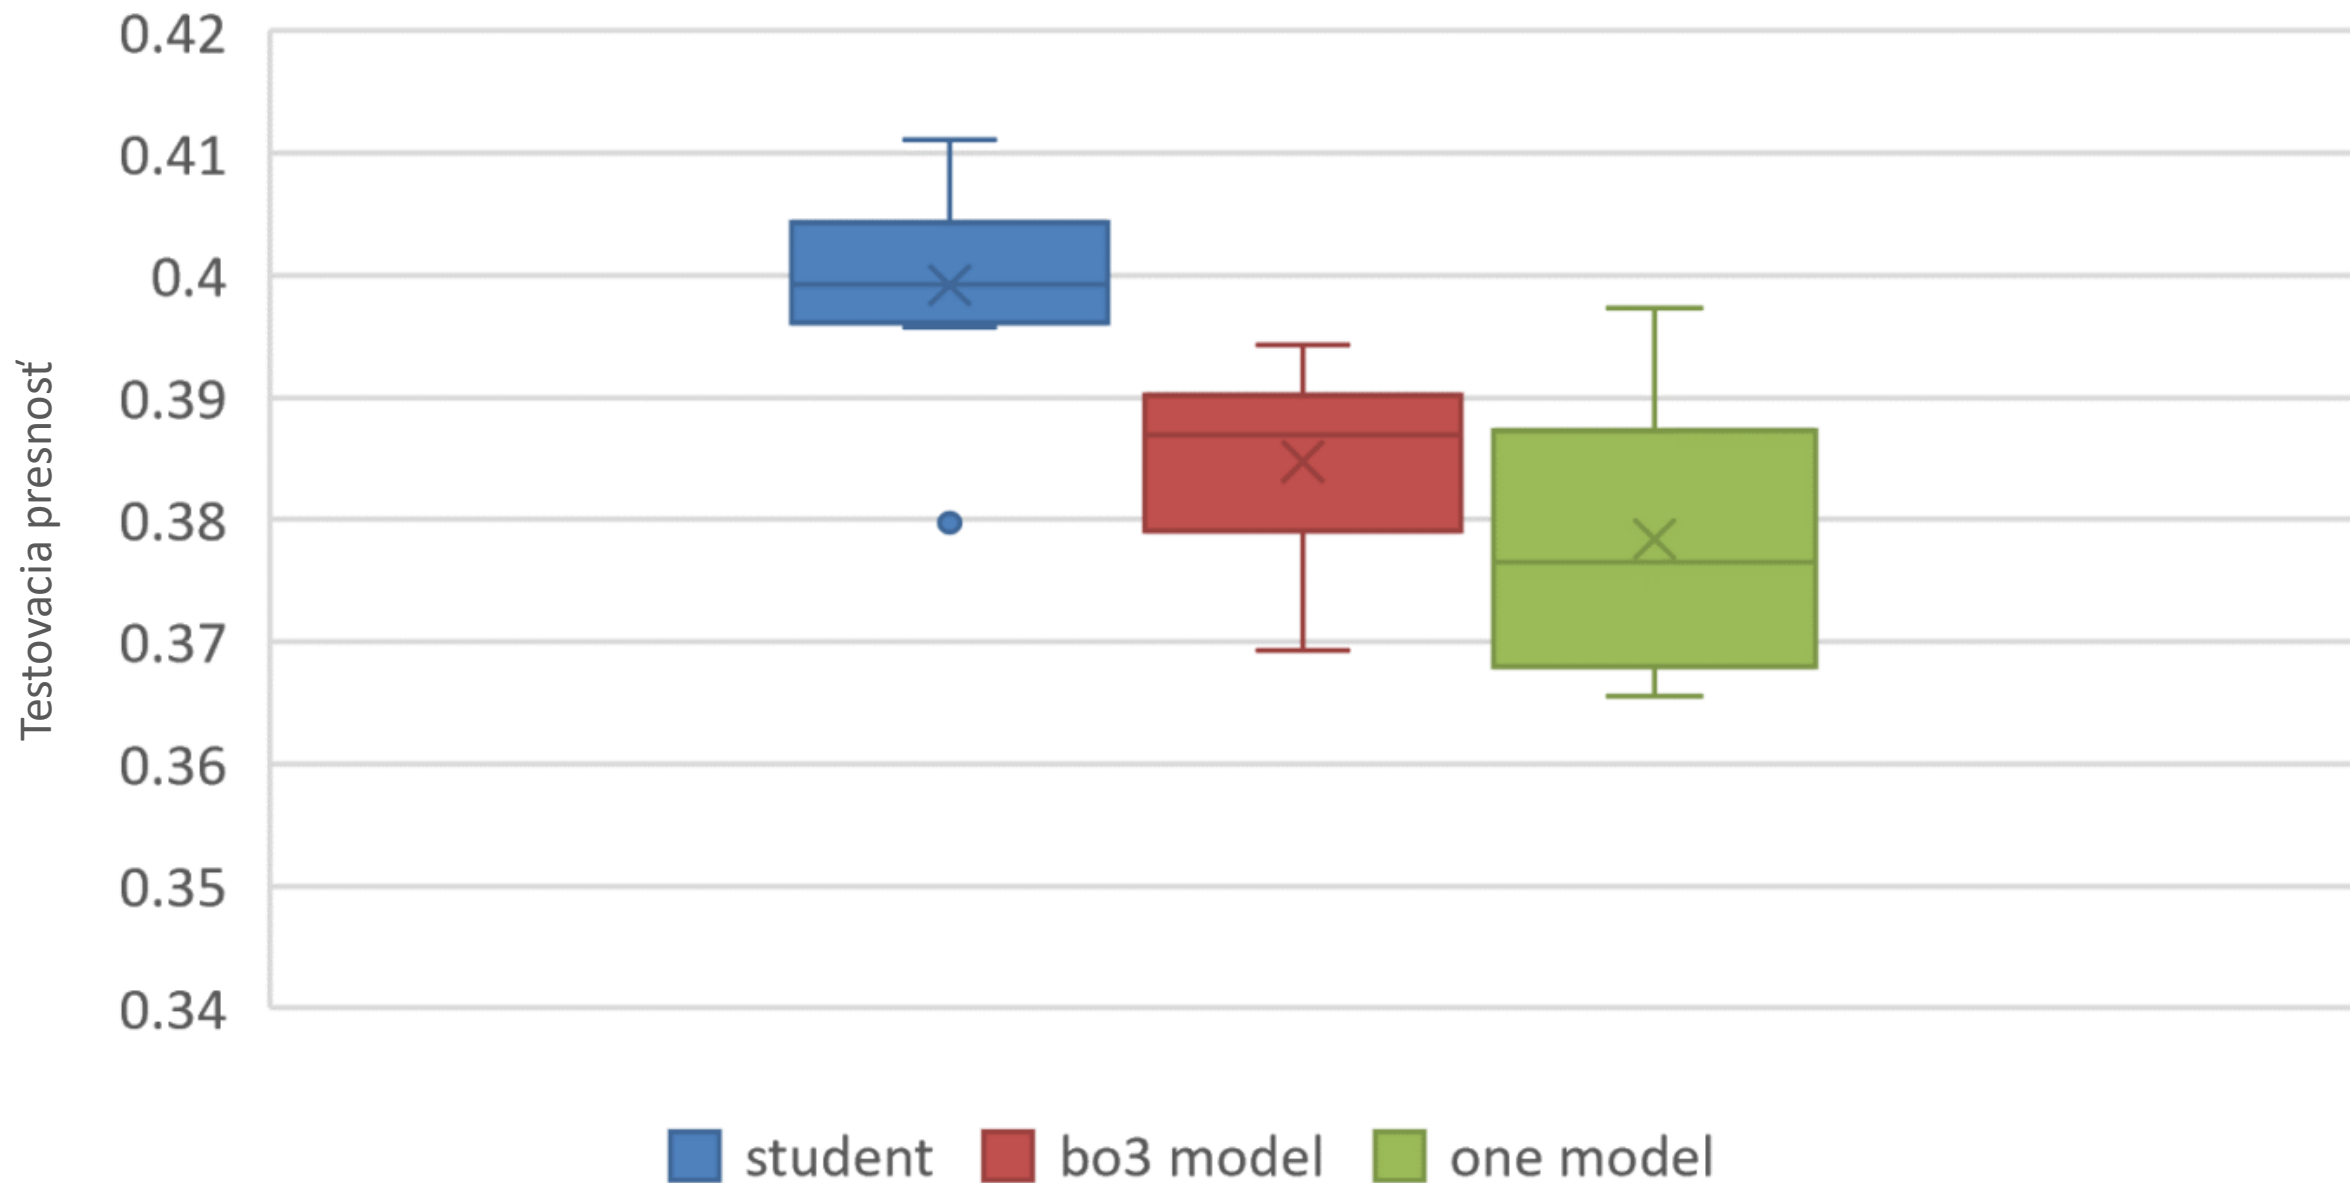
bo3 model



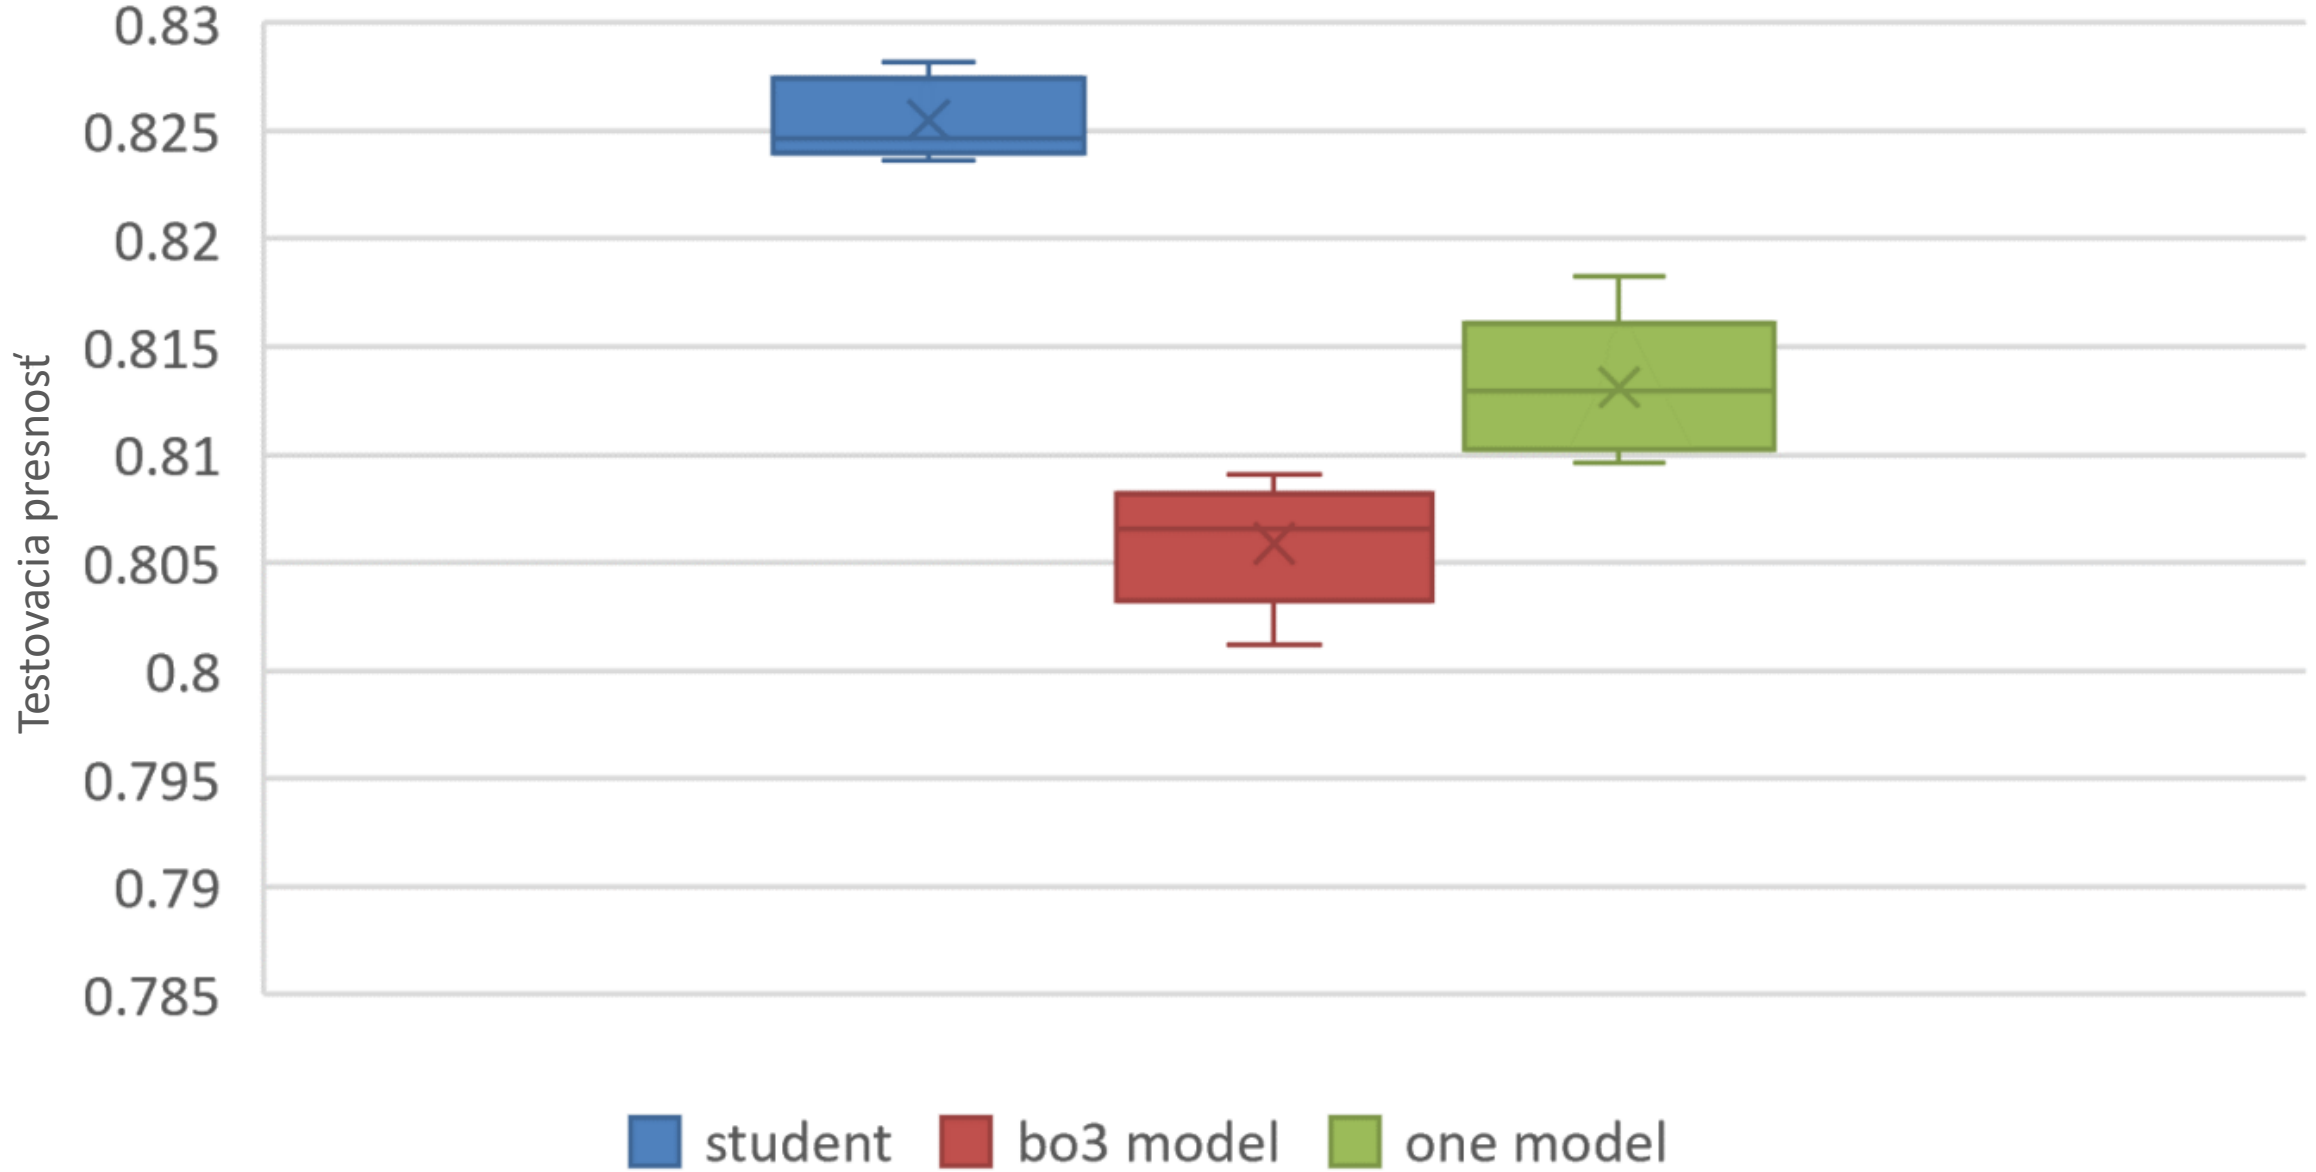
one_model




Imagewoof - LeNet



Imagewoof - ResNet-18



Cifar 100 - ResNet-20



ResNet-18 a ImageNet 1k

Epochy - učiteľ	Epochy – spájanie	Epochy – dotrénovanie	Epochy – spolu	Testovacia presnosť
-	-	90	90	69,76%
-	-	150	150	70,28%
20 + 20	20	90	150	70,47%

Ďakujem za pozornosť