

Kapitola 1

Perceptron

JL: Nápad k perceptronu – že můžeme rysy sečíst, když působí společně, ale nevíme v jakém poměru.

JL: parametrický model, KNN byl neparametrický

TM: zavést lin. separabilitu?

1.1 Model

$$y = \begin{cases} 1 & \text{pokud } \sum_{i=1}^n w_i x_i \geq b \\ 0 & \text{jinak} \end{cases} \quad (1.1)$$

1.2 Algoritmus učení

TM: t = čas

$$w_{t+1} = w_t - (y - t)x \quad (1.2)$$

1.3 Předzpracování dat

TM: heuristika pro počáteční nastavení vah: průměr pozitivních minus průměr negativních vzorů

TM: modifikace: parametr rychlosti učení

JL: Learning curve

TM: přihrádkový algoritmus učení – pamatuju si nejlepší váhový vektor a kolik vzorů poznal správně

JL: accuracy = správnost, co precision a recall? (přesnost a úplnost)

TM: důkaz konvergence

JL: praktické aspekty: silně korelované featury zpomalují konvergenci, protože dochází ke smyčkám (obě rysy spolu cyklicky zesilují a zespabují), antikorelované silné featury zase vedou k vysokým hodnotám vah a v praxi výpočet nekonverguje

JL: Averaged perceptron? Částečně řeší výše uvedené problémy

JL: accuracy – porovnat s KNN, ať vidí, že se metody často porovnávají