

Obrada prirodnih jezika

Elektrotehnički fakultet Univerziteta u Beogradu

Master akademske studije

modul Softversko inženjerstvo

2017/2018

Metoda potpornih vektora

Vuk Batanović, Elektrotehnički fakultet Univerziteta u Beogradu

Metoda potpornih vektora

- ▶ Metoda potpornih vektora (engl. *Support Vector Machines - SVM*)
- ▶ Binarni klasifikator
 - ▶ Najčešće se jedna klasa označava sa $y = +1$ a druga sa $y = -1$
- ▶ Osnovna verzija algoritma je linearni klasifikator
- ▶ Neprobabilistički klasifikator - izlaz modela je samo klasifikaciona odluka
- ▶ Pošto direktno modeluje granicu između klasa, metoda potpornih vektora spada u diskriminativne modele

Metoda potpornih vektora - istorijat

- ▶ Osnovnu varijantu metode potpornih vektora su predstavili Vladimir Vapnik i Aleksej Červonenkis 1963. godine
- ▶ 1992. godine je grupa autora (uključujući Vapnika) predložila proširenje na nelinearne slučajeve korišćenjem kernelskog trika (engl. *kernel trick*)
- ▶ Kortez i Vapnik su 1993. godine predložili, a 1995. godine objavili varijantu algoritma sa mekim marginama (engl. *soft margin*)

Izbor hiperravnih razdvajanja

- ▶ Pri klasifikaciji podataka potrebno je pronaći hiperravan koja razdvaja podatke koji pripadaju različitim klasama
- ▶ Ako su podaci linearno separabilni moguće je pronaći beskonačno mnogo hiperravnih koje su u stanju da izvrše razdvajanje podataka iz skupa za obučavanje
- ▶ Pitanje - po kom kriterijumu odabratiti jednu od njih?
 - ▶ Logistička regresija - kriterijum je maksimalna entropija modela
 - ▶ Metoda potpornih vektora - kriterijum je maksimalna margina između klasa

Maksimalna margina razdvajanja i potporni vektori

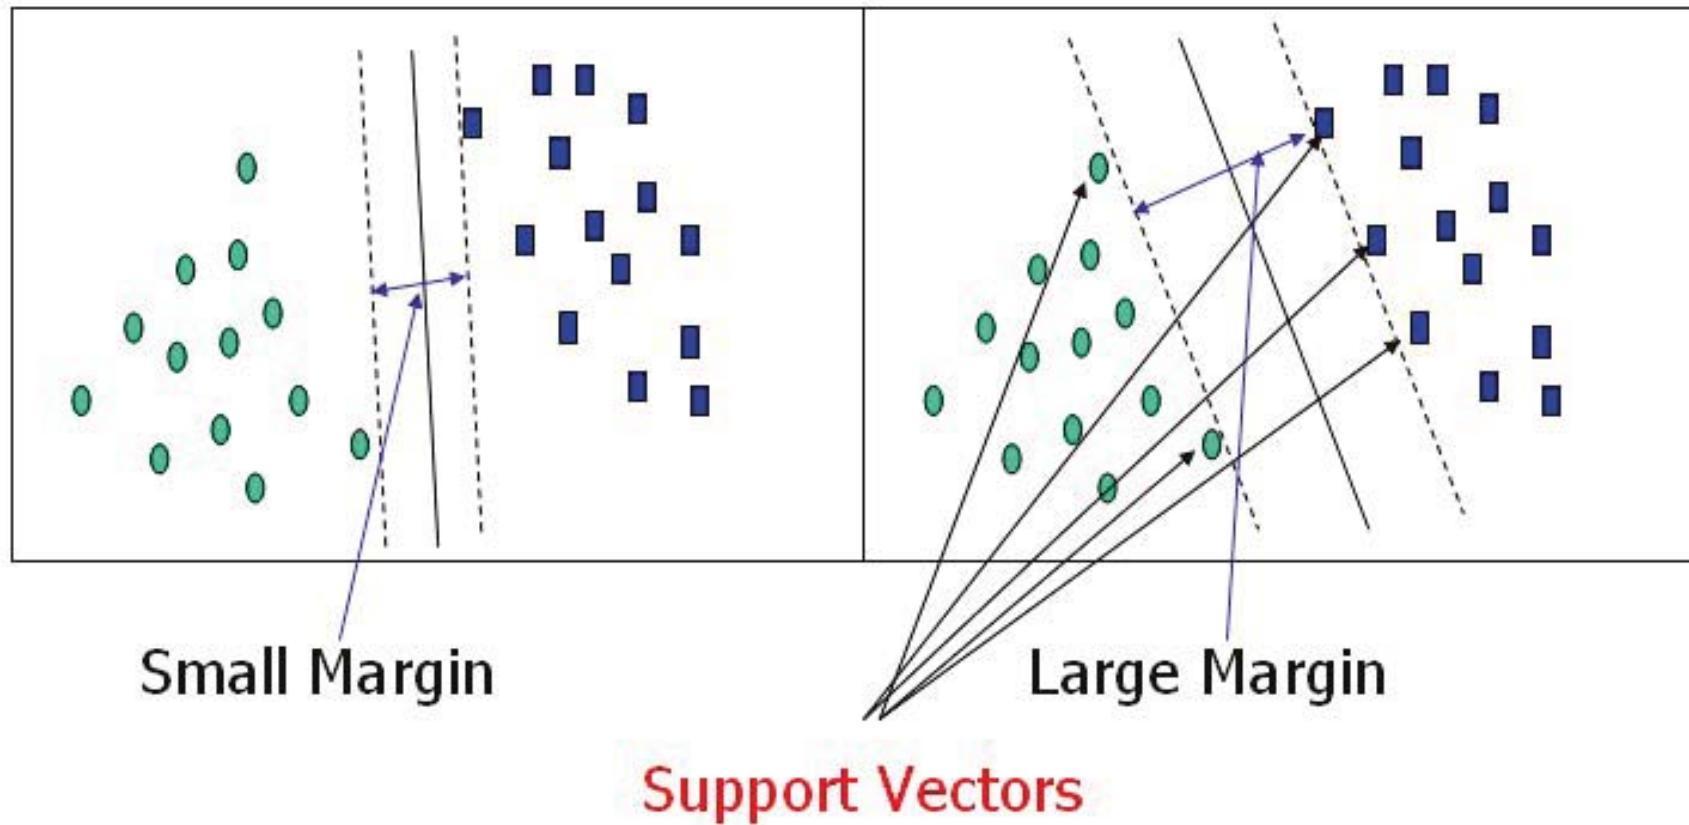
- ▶ Ako su podaci linearno separabilni, onda je moguće zamisliti dve paralelne hiperravni takve da razdvajaju podatke različitih klasa i da se između njih ne nalazi ni jedan podatak
- ▶ Oblast prostora između ovih zamišljenih hiperravnih se naziva *marginom*
- ▶ Cilj obučavanja modela u metodi potpornih vektora je da se pronađe maksimalna margina
- ▶ Obe zamišljene hiperravni efektivno naležu na jedan ili više podataka svoje klase - ti podaci su *potporni vektori* (engl. *support vectors*)
 - ▶ Potporni vektori „podupiru“ zamišljene hiperravni
 - ▶ Naziv *vektor* potiče od posmatranja svakog podatka kao vektora/tačke u n -dimenzionalnom prostoru

Maksimalna margina razdvajanja i potporni vektori

- ▶ Intuitivno gledano, hiperravan razdvajanja koja prolazi kroz sredinu praznine između podataka dveju klase ima više smisla od one koja se nalazi blizu podataka bilo jedne bilo druge klase
- ▶ Biranjem hiperravnih razdvajanja koja se nalazi najdalje od uočenih podataka efektivno se minimizuje greška generalizacije modela (tj. greška na novim podacima)
 - ▶ Pod pretpostavkom da će i novi podaci biti generisani iz iste raspodele kao i postojeći
- ▶ Ovo se razlikuje od pristupa u logističkoj regresiji gde se minimizuje empirijska greška na već raspoloživim podacima za obučavanje (tj. maksimizuju performanse modela na njima)

Maksimalna margina razdvajanja i potporni vektori

- ▶ Pri traženju hiperravni razdvajanja sa maksimalnom marginom položaj podataka koji su udaljeniji od hiperravni razdvajanja nije bitan - oni ne utiču na marginu razdvajanja podataka
- ▶ Hiperravan razdvajanja je određena malim brojem podataka obe klase koji su joj najbliži
 - ▶ Oni su najvažniji za pravilnu klasifikaciju kako postojećih tako i novih podataka
- ▶ Ovo je drugačije od logističke regresije gde hiperravan razdvajanja zavisi od položaja svih podataka



Ilustracija veličine margine razdvajanja i potpornih vektora

Slika preuzeta sa: <http://www.dtreg.com/solution/view/20>

Hipoteza metode potpornih vektora

- ▶ U metodi potpornih vektora model predstavlja jednačinu hiperravnog razdvajanja
- ▶ Ako je n broj odlika koje se koriste u modelu tj. broj dimenzija prostora, onda je hipoteza oblika:

$$h(x) = w_0 + w_1x_1 + w_2x_2 + \cdots + w_nx_n = W^T X + w_0$$

- ▶ Često se umesto oznake w_0 koristi oznaka b (engl. *bias term*)
- ▶ Jednačina hiperravnog razdvajanja je:

$$h(x) = W^T X + w_0 = 0$$

- ▶ Vektor W je vektor normale na hiperravan razdvajanja

Skaliranje jednačine hiperravni razdvajanja

- ▶ Jednačina hiperravni razdvajanja se može pomnožiti/podeliti bilo kojim pozitivnim brojem bez promene položaja hiperravni
- ▶ Iako je faktore W i w_0 moguće proizvoljno skalirati, konvencionalno se usvaja takva kanonska vrednost da za potporne vektore $X^{(sv)}$ važi

$$y^{(sv)}(W^T X^{(sv)} + w_0) = 1$$

- ▶ To znači da jednačina hiperravni koja „naleže“ na potporne vektore iz klase $y = 1$ postaje:

$$W^T X + w_0 = 1$$

- ▶ dok je jednačina hiperravni koja „naleže“ na potporne vektore iz klase $y = -1$:

$$W^T X + w_0 = -1$$

Širina margine razdvajanja

- ▶ Udaljenost neke tačke/podataka $X^{(a)}$ od hiperravni razdvajanja Π je:

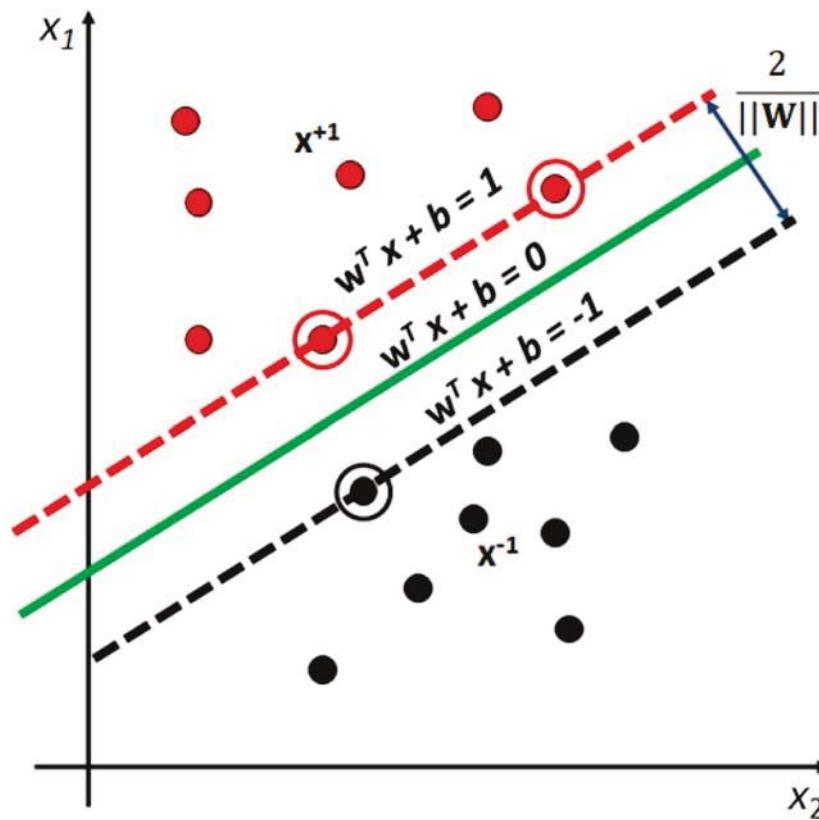
$$dist(X^{(a)}, \Pi) = \frac{|W^T X^{(a)} + w_0|}{\|W\|_2}$$

- ▶ Sledi da je udaljenost potpornih vektora $X^{(sv)}$ od hiperravni razdvajanja:

$$dist(X^{(sv)}, \Pi) = \frac{|W^T X^{(sv)} + w_0|}{\|W\|_2} = \frac{1}{\|W\|_2}$$

- ▶ Pošto se potporni vektori nalaze sa obe strane hiperravni razdvajanja, širina margine je dvostruko veća - nju treba maksimizovati:

$$\operatorname{argmax}_{W, w_0} \frac{2}{\|W\|_2}$$



Udaljenost potpornih vektora od hiperravnog razdvajanja

Slika preuzeta sa: <http://jap.physiology.org/content/115/11/1714>

Cilj obučavanja u metodi potpornih vektora

- ▶ Pošto marginu treba maksimizovati, sledi da treba minimizovati $\|W\|_2$
- ▶ Pošto je

$$\|W\|_2 = \sqrt{w_1^2 + w_2^2 + \dots + w_n^2}$$

- ▶ sa stanovišta optimizacije lakše je izbeći korenu funkciju i minimizovati $\frac{1}{2} \|W\|_2^2$
 - ▶ Ovu zamenu je moguće sprovesti jer minimizovanje kvadrata norme minimizuje i samu normu
- ▶ Stoga je cilj obučavanja u metodi potpornih vektora pronaći

$$\operatorname{argmin}_{W, w_0} \frac{1}{2} \|W\|_2^2$$

Uslovi pri traženju maksimalne margine

- ▶ Prilikom pronalaženja maksimalne margine treba sprečiti da neki podatak bilo prve bilo druge klase upadne u marginu, što znači da treba da važi:

$$W^T X^{(+1)} + w_0 \geq 1$$

- ▶ gde su $X^{(+1)}$ podaci klase $y = +1$, odnosno:

$$W^T X^{(-1)} + w_0 \leq -1$$

- ▶ gde su $X^{(-1)}$ podaci klase $y = -1$
- ▶ Navedeni uslovi se mogu uprostiti na:

$$y^{(i)}(W^T X^{(i)} + w_0) \geq 1$$

Optimizacioni problem

- ▶ Optimizacioni problem ima sledeći oblik:

$$\operatorname{argmin}_{W, w_0} \frac{1}{2} \|W\|_2^2, \quad y^{(i)}(W^T X^{(i)} + w_0) \geq 1, \quad i = 1, 2, \dots, m$$

- ▶ gde je m broj podataka u skupu za obučavanje
- ▶ Ovo je problem konveksne optimizacije sa ograničenjem, tj. kvadratnog programiranja
- ▶ Do rešenja se može doći tehnikom Lagranžovih multiplikatora uz Karush-Kuhn-Tucker-ove (KKT) uslove
- ▶ Ovo rešenje podrazumeva kreiranje tzv. dualne reprezentacije problema u kojoj se za svaku nejednakost navedenog oblika kreira po jedan Lagranžov multiplikator α_k

Dualna formulacija hipoteze metode potpornih vektora

- ▶ U dualnoj reprezentaciji problema dobija se da je:

$$W = \sum_{i=1}^m \alpha_i y^{(i)} X^{(i)}$$

$$h(x) = W^T X + w_0 = \sum_{i=1}^m \alpha_i y^{(i)} (X^{(i)})^T X + w_0$$

- ▶ Pokazuje se da su optimalne vrednosti α_i dodeljene svakoj tački jednake nuli za sve tačke osim za potporne vektore
 - ▶ Njih obično ima mnogo manje od ukupnog broja tačaka
- ▶ Stoga vrednost hipoteze (i jednačina hiperravni razdvajanja) zavise samo od potpornih vektora

Dualna formulacija hipoteze metode potpornih vektora

- ▶ Vrednost hipoteze $h(x^{(k)})$ za neki nov podatak $x^{(k)}$ zavisi od proizvoda

$$(X^{(i)})^T X^{(k)} = X^{(i)} \cdot X^{(k)}$$

- ▶ tj. od sličnosti potpornih vektora $X^{(i)}$ sa vektorom novog podatka $X^{(k)}$
- ▶ Klasifikovanje podatka predstavlja proveru sa koje strane hiperravnji razdvajanja se on nalazi:

$$\hat{y} = sign(h(x))$$

Meka margina

- ▶ Insistiranje na linearnoj separabilnosti klasa, čak i ako je ona moguća, može da dovede do preterane prilagođenosti modela podacima
 - ▶ Pravi probleme u slučaju prisustva *outlier-a* - pronađeno rešenje će imati malu marginu tj. slabu generalizaciju na nove podatke
- ▶ Umesto toga, bolje je (u ograničenoj meri) dozvoliti ulaske podataka u marginu ili njihov prelazak na pogrešnu stranu hiperravnog razdvajanja
- ▶ Margina u kojoj je ovo dozvoljeno se naziva mekom marginom (engl. *soft margin*)

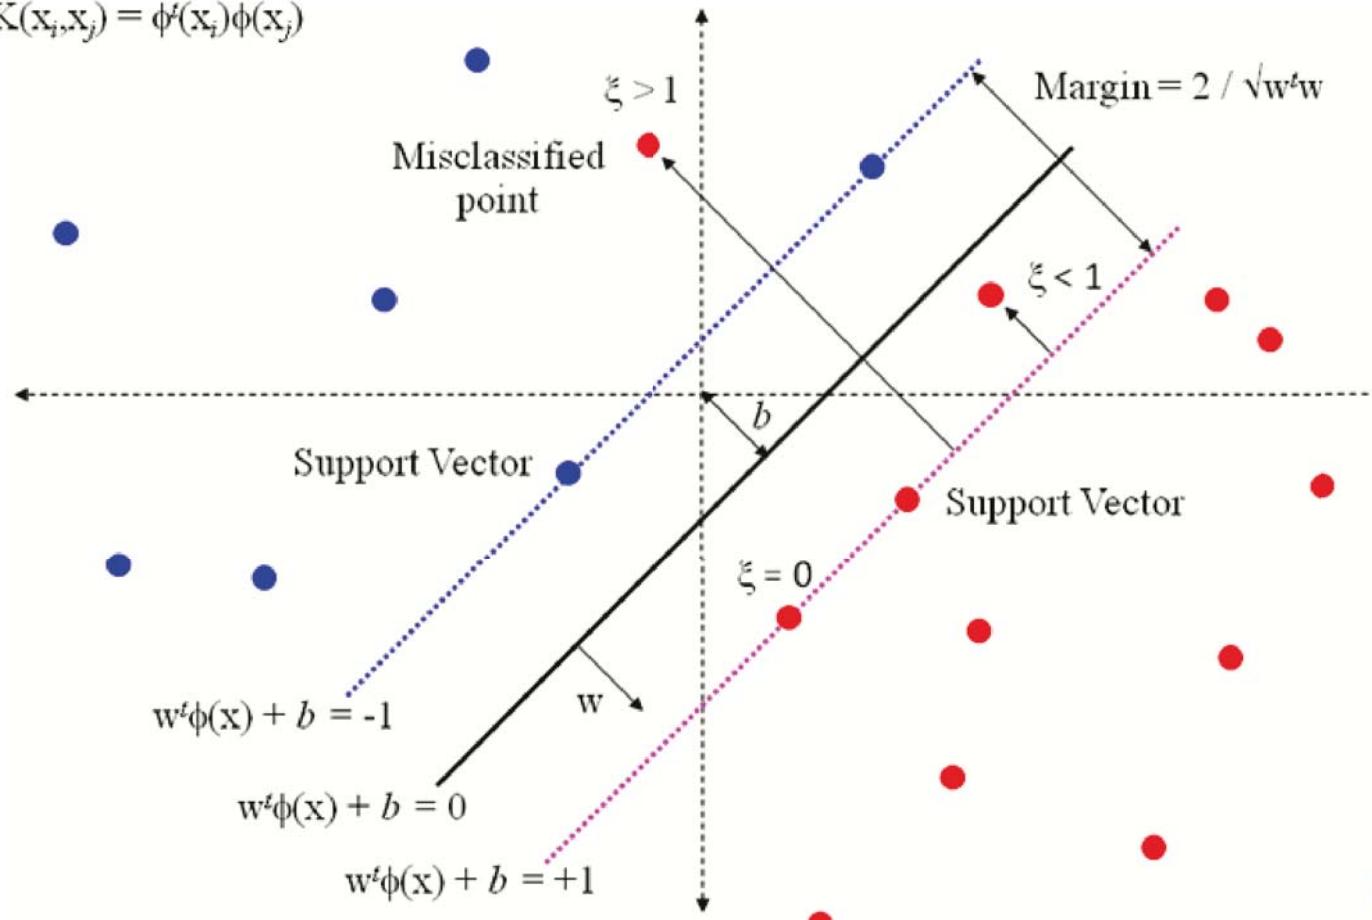
Meka margina

- ▶ Korišćenje meke margine dovodi do reformulacije optimizacionog problema:

$$\operatorname{argmin}_{W, w_0} \frac{1}{2} \|W\|_2^2, \quad y^{(i)}(W^T X^{(i)} + w_0) \geq 1 - \xi_i, \quad \xi_i \geq 0, \\ i = 1, 2, \dots, m$$

- ▶ gde su ξ_i prekoračenja u položaju svake tačke izvan granice njene klase (engl. *slack variables*)
- ▶ Ukoliko je
 - ▶ $\xi_i = 0$ - podatak je pravilno klasifikovan i izvan margine
 - ▶ $1 \geq \xi_i > 0$ - podatak je pravilno klasifikovan ali unutar margine
 - ▶ $\xi_i > 1$ - podatak nije pravilno klasifikovan - nalazi se sa suprotne strane hiperravnih razdvajanja u odnosu na njegovu klasu

$$K(x_i, x_j) = \phi(x_i)\phi(x_j)$$



Ilustracija meke marge u metodi potpornih vektora

Slika preuzeta sa: <http://steve-cronin.blogspot.rs/2010/09/modern-analytics-look-at-smo.html>

Funkcija gubitka kod SVM-a sa mekom marginom

- ▶ Svaki podatak koji uđe u marginu ili pređe na pogrešnu stranu hiperravnog razdvajanja treba penalizovati proporcionalno njegovoj udaljenosti od ivice margine na strani klase kojoj pripada
- ▶ Funkcija gubitka može imati dva oblika

- ▶ L_1 oblik funkcije gubitka:

$$L(h(x), y) = \xi$$

- ▶ L_2 oblik funkcije gubitka:

$$L(h(x), y) = \xi^2$$

Gubitak u obliku šarke

- ▶ Funkcija gubitka SVM-a sa mekom marginom se naziva i gubitkom u obliku šarke (engl. *hinge loss*)
- ▶ Uslov meke margine za jedan podatak se može preformulisati kao:

$$y(W^T X + w_0) \geq 1 - \xi$$

$$yh(x) \geq 1 - \xi$$

$$\xi \geq 1 - yh(x)$$

- ▶ Ako se uzme u obzir i uslov da je $\xi \geq 0$, sledi:

$$\xi = \max(0, 1 - yh(x))$$

- ▶ Ako se usvoji da je $z = y(W^T X + w_0)$, onda je gubitak u obliku šarke:

$$\xi = \max(0, 1 - z)$$

Reformulacija logističke funkcije gubitka za $y \in \{-1,1\}$

- Logistička funkcija gubitka ima sledeći oblik za $y \in \{0,1\}$:

$$L(h(x), y) = -\ln(P(y|x)) = \begin{cases} -\ln(P(y=1|x)) = -\ln(h(x)), & y = 1 \\ -\ln(P(y=0|x)) = -\ln(1-h(x)), & y = 0 \end{cases}$$

- Ako se koriste oznake $y \in \{-1,1\}$ za klase, onda važi:

$$P(y=1|x) = \frac{1}{1 + e^{-(W^T X + w_0)}}$$

$$P(y=-1|x) = \frac{1}{1 + e^{W^T X + w_0}}$$

$$P(y|x) = \frac{1}{1 + e^{-y(W^T X + w_0)}}$$

Reformulacija logističke funkcije gubitka za $y \in \{-1,1\}$

- ▶ Sledi da je za $y \in \{-1,1\}$:

$$-\ln(P(y|x)) = -\ln \frac{1}{1 + e^{-y(W^T X + w_0)}} = \ln(1 + e^{-y(W^T X + w_0)})$$

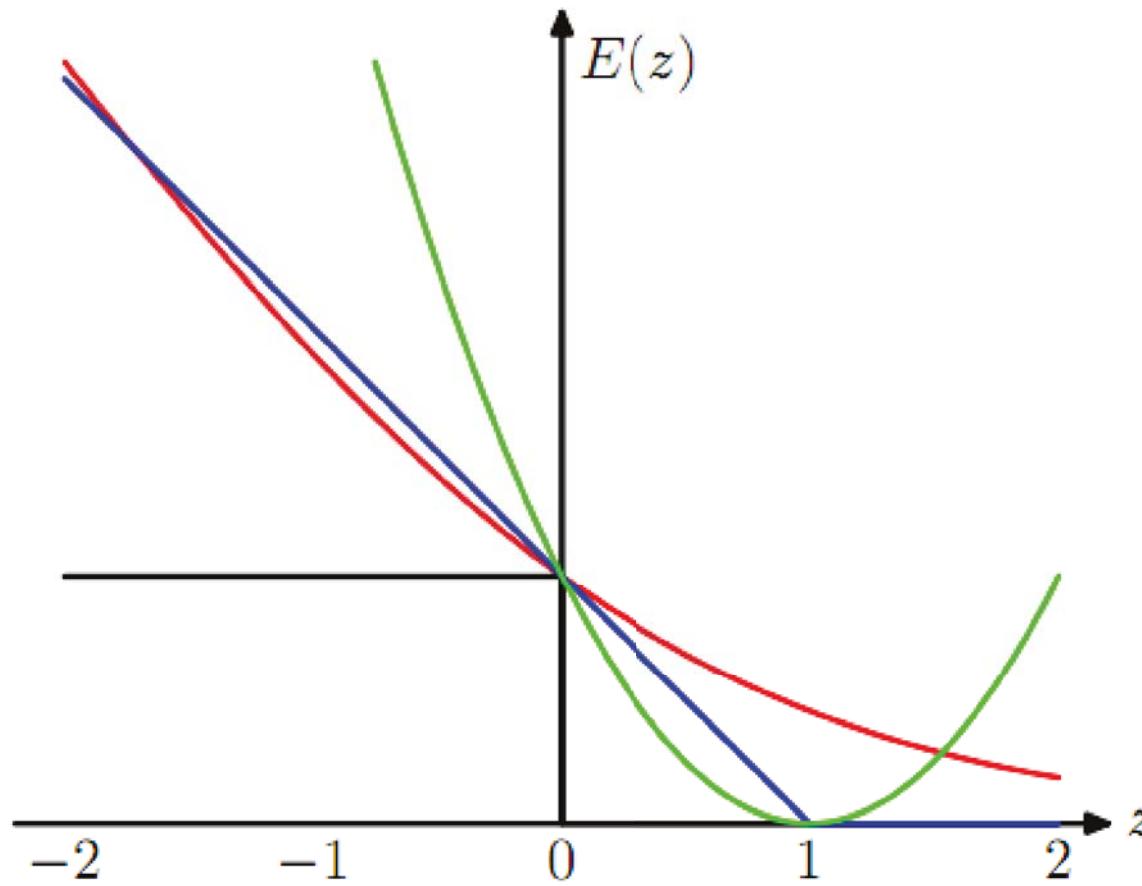
- ▶ Logistička funkcija gubitka za $y \in \{-1,1\}$ se obično skalira sa $\frac{1}{\ln 2}$:

$$L(h(x), y) = \frac{1}{\ln 2} \ln(1 + e^{-y(W^T X + w_0)})$$

- ▶ Razlog za skaliranje - ako se usvoji da je $z = y(W^T X + w_0)$, onda logistička funkcija gubitka

$$L(z) = \frac{1}{\ln 2} \ln(1 + e^{-z})$$

- ▶ prolazi kroz tačku $(0,1)$



Poređenje oblika različitih funkcija gubitka

Legenda: 0-1 gubitak (crna), gubitak u obliku šarke (plava), logistička funkcija gubitka (crvena), kvadratna funkcija gubitka (zelena)

Slika preuzeta iz: Christopher Bishop, Pattern Recognition and Machine Learning

Funkcija greške kod SVM-a sa mekom marginom

- ▶ U metodi potpornih vektora sa mekom marginom postoje dva različita (i ponekad suprotstavljeni) cilja optimizacije
 - ▶ Maksimizacija margine
 - ▶ Minimizacija greške klasifikacije na pojedinačnim primerima tj. gubitka u obliku šarke
- ▶ Funkcija greške kod SVM-a sa mekom marginom ima oblik:

$$J(w) = C \sum_{i=1}^m L(h(x^{(i)}), y^{(i)}) + \frac{1}{2} \sum_{j=1}^n w_j^2$$

- ▶ C je hiperparametar modela koji određuje balans između dva cilja optimizacije
- ▶ Cilj obučavanja je minimizacija funkcije greške $J(w)$

Funkcija greške kod SVM-a sa mekom marginom

- ▶ Ukoliko se koristi L_1 oblik funkcije gubitka, onda je funkcija greške:

$$\begin{aligned} J(w) &= C \sum_{i=1}^m \xi_i + \frac{1}{2} \sum_{j=1}^n w_j^2 \\ &= C \sum_{i=1}^m \max(0, 1 - y^{(i)} h(x^{(i)})) + \frac{1}{2} \sum_{j=1}^n w_j^2 \end{aligned}$$

- ▶ Ukoliko se koristi L_2 oblik funkcije gubitka, onda je funkcija greške:

$$\begin{aligned} J(w) &= C \sum_{i=1}^m \xi_i^2 + \frac{1}{2} \sum_{j=1}^n w_j^2 \\ &= C \sum_{i=1}^m \left(\max(0, 1 - y^{(i)} h(x^{(i)})) \right)^2 + \frac{1}{2} \sum_{j=1}^n w_j^2 \end{aligned}$$

Funkcija greške kod SVM-a sa mekom marginom

- ▶ L_2 oblik funkcije gubitka
 - ▶ Rešenje je stabilnije (male promene u podacima za obučavanje manje utiču na rešenje)
 - ▶ Manja otpornost na uticaj *outlier*-a
- ▶ L_1 oblik funkcije gubitka
 - ▶ Rešenje je manje stabilno (male promene u podacima za obučavanje više utiču na izgled rešenja)
 - ▶ Veća otpornost na uticaj *outlier*-a

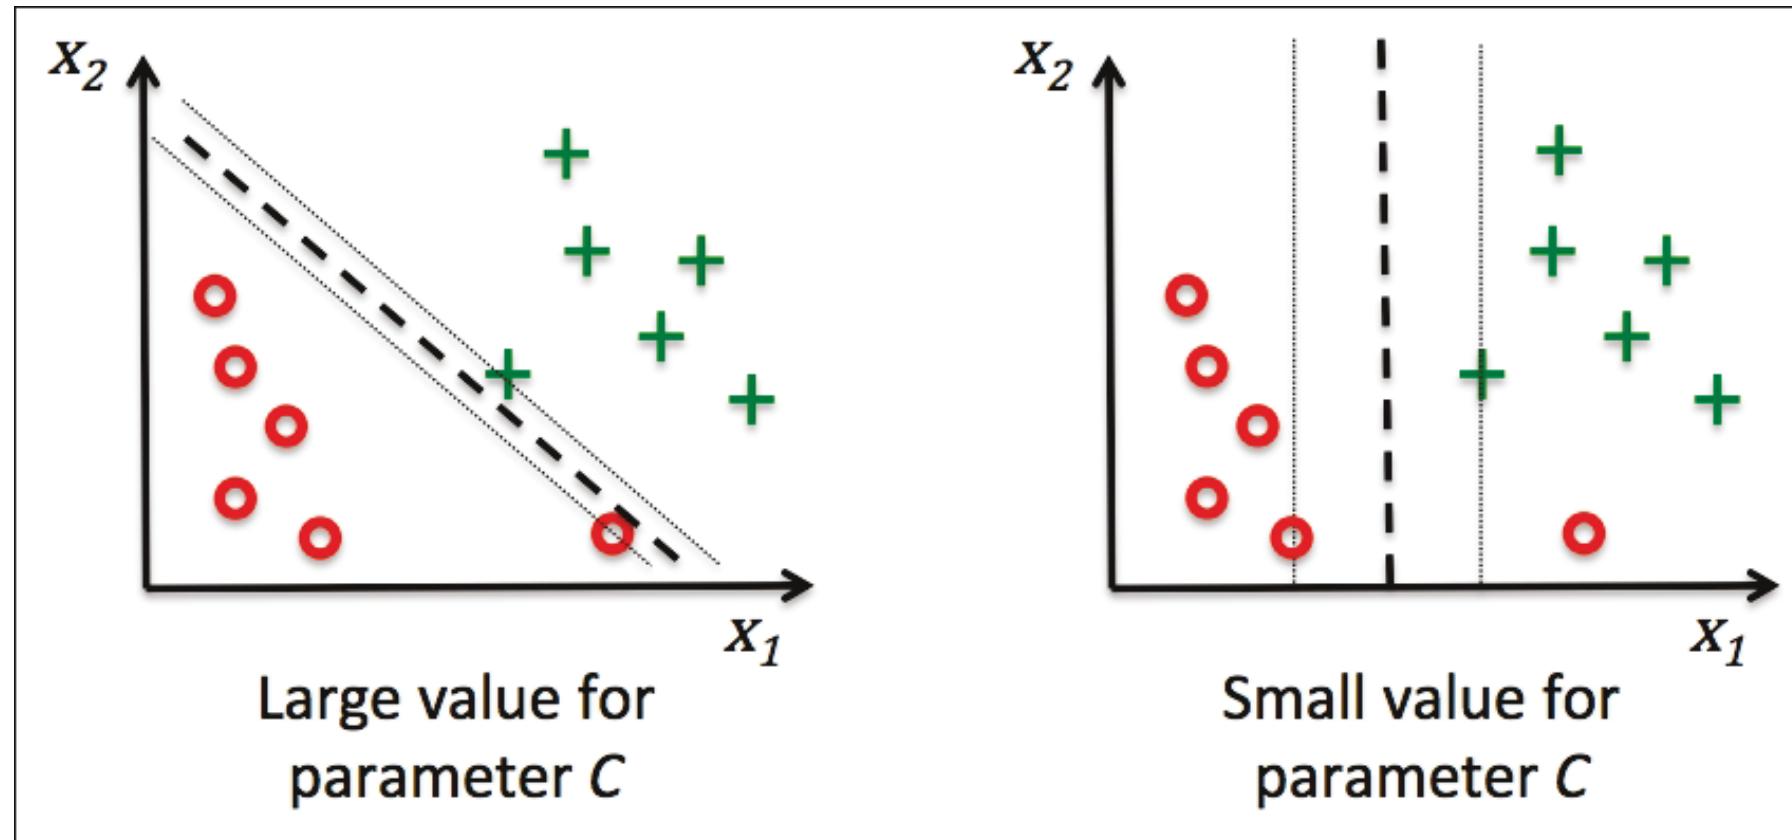
Regularizacija kod SVM sa mekom marginom

- ▶ Veća margina povećava generalizaciju modela - minimizovanje norme vektora W predstavlja regularizaciju modela
- ▶ Moguće je koristiti L_1 ili L_2 regularizaciju
 - ▶ U L_2 regularizaciji se minimizuje do sada korišćen izraz $\frac{1}{2} \|W\|_2^2$
 - ▶ U L_1 regularizaciji se minimizuje vrednost $\|W\|_1$
 - ▶ Sve ranije prikazane razlike između ova dva tipa regularizacije važe i kod metode potpornih vektora

Hiperparametar C

- ▶ Velika vrednost C - model se pri obučavanju fokusira na smanjivanje greške klasifikacije, po cenu manje margine razdvajanja, čime se smanjuje stepen regularizacije
- ▶ Mala vrednost C - model se pri obučavanju fokusira na povećanje margine razdvajanja, čime se povećava stepen regularizacije, po cenu veće greške klasifikacije
- ▶ Po svojoj funkciji hiperparametar C je inverzan hiperparametru λ koji određuje jačinu regularizacije u linearnoj i logističkoj regresiji:

$$C = \frac{1}{\lambda}$$



Slika preuzeta iz: Sebastian Raschka, Python Machine Learning

SVM optimizacija u primarnom domenu

- ▶ Funkciju greške je moguće minimizovati i u primarnom domenu, bez korišćenja Lagranžovih multiplikatora i prelaska u dualni domen
- ▶ Dualni pristup može biti spor kada je količina podataka u skupu za obučavanje jako velika, pošto je tada obično i broj potpornih vektora veliki
- ▶ Primenuju se naprednije tehnike numeričke optimizacije, kao što je subgradijentni spust
 - ▶ Često se traži aproksimacija optimalnog rešenja, a ne tačno rešenje
- ▶ Kada je broj odlika znatno veći od broja podataka u skupu za obučavanje može biti preporučljivije da se optimizacija radi u dualnom domenu

Višeklasna klasifikacija

- ▶ Metoda potpornih vektora se može primeniti i u slučaju prisustva većeg broja klasa, i to kombinovanjem rezultata većeg broja nezavisnih binarnih klasifikacija
 - ▶ Princip „jedan nasuprot svima“ (engl. *one-versus-all*) / „jedan nasuprot ostalima“ (engl. *one-versus-rest*)
 - ▶ Podatak se svrstava u onu klasu čiji binarni klasifikator klasificuje dati podatak u tu klasu sa najvećom udaljenošću između njegove hiperravnog razdvajanja i podatka (umesto najveće verovatnoće pripadanja određenoj klasi u slučaju logističke regresije)
 - ▶ Princip „jedan nasuprot jednom“ (engl. *one-versus-one*)
- ▶ Postoje i pristupi koji istovremeno modeluju prisustvo više klasa
 - ▶ Crammer & Singer algoritam

Prednosti i mane metode potpornih vektora

- ▶ Prednosti
 - ▶ Veoma dobre performanse na širokom spektru problema
 - ▶ Metoda sama odabira koji podaci su potporni vektori i koliko ih ima
 - ▶ Manja sklonost *overfitting*-u od mnogih drugih metoda
- ▶ Mane
 - ▶ SVM može da bude primetno sporiji od drugih metoda, u zavisnosti od broja odlika i količine podataka u skupu za obučavanje
 - ▶ Izlaz nije probabilističkog tipa
 - ▶ Moguća probabilistička procena preko udaljenosti od hiperravnog razdvajanja
 - ▶ Varijanta sa čvrstom marginom je osetljiva na *outlier*-e