Kỷ yếu Hội nghị Khoa học Quốc gia lần thứ IX "Nghiên cứu cơ bản và ứng dụng Công nghệ thông tin (FAIR'9)"; Cần Thơ, ngày 4-5/8/2016
DOI: 10.15625/vap.2016.00066

PHÂN LỚP HIỆU QUẢ TẬP DỮ LIỆU LỚN VỚI GIẢI THUẬT GIẢM GRADIENT NGẪU NHIÊN

Đỗ Thanh Nghị, Phạm Thế Phi
Khoa CNTT-TT, Trường Đại học Cần Thơ
Khu 2, Đường 3/2, Xuân Khánh, Ninh Kiều, TP. Cần Thơ
{dtnghi,ptphi}@cit.ctu.edu.vn

TÓM TẮT— *Trong bài viết này, chúng tôi trình bày giải thuật giảm gradient ngẫu nhiên sử dụng trong máy học véctơ hỗ trợ cho phân lớp nhanh tập dữ liệu lớn. Máy học véctơ hỗ trợ sử dụng hàm hinge loss trong phân lớp nhằm đạt được tính chất thưa trong lời giải. Tuy nhiên, do hàm hinge loss không khả vi là nguyên nhân làm chậm hội tụ đến lời giải khi áp dụng giải thuật giảm gradient ngẫu nhiên. Chúng tôi nghiên cứu thay thế hàm hinge loss được sử dụng trong vấn đề tối ưu của giải thuật máy học véctơ hỗ trợ bằng các hàm xấp xỉ, khả vi nhằm cải tiến tốc độ hội tụ của giải thuật giảm gradient ngẫu nhiên. Kết quả thực nghiệm trên 2 tập dữ liệu văn bản lớn (RCV1, twitter) cho thấy hiệu quả của đề xuất sử dụng hàm xấp xỉ so với hàm hinge loss.*

Từ khóa— *Máy học véctơ hỗ trợ (SVM), giảm gradient ngẫu nhiên (SGD), phân lớp dữ liệu lớn.*

I. GIỚI THIỆU

Máy học véctơ hỗ trợ (Support Vector Machines - SVM [Vapnik, 1995]) là lớp mô hình máy học hiệu quả để giải quyết các vấn đề phân lớp, hồi quy, phát hiện phần tử cá biệt. Máy học SVM đã được áp dụng thành công trong rất nhiều ứng dụng như nhận dạng mặt người, phân loại văn bản, phân loại bệnh ung thư (tham khảo tại [Guyon, 1999]). Giải thuật máy học SVM có thể sử dụng các hàm hạt nhân (kernel function), cung cấp các mô hình có độ chính xác rất cao cho các vấn đề phân lớp và hồi quy phi tuyến trong thực tế. Mặc dù có được những ưu điểm kể trên, giải thuật huấn luyện một mô hình SVM rất mất thời gian và tiêu tốn nhiều không gian bộ nhớ do phải giải bài toán quy hoạch toàn phương (quadratic programming). Độ phức tạp tối thiểu của giải thuật huấn luyện mô hình SVM là bậc 2 so với số lượng phần tử dữ liệu [Platt, 1999]. Do đó, cần thiết phải có những cải tiến để giải thuật học SVM có thể xử lý được các tập dữ liệu với kích thước lớn về số phần tử cũng như số chiều.

Để cải tiến việc huấn luyện giải thuật máy học SVM cho các tập dữ liệu lớn. Các công trình nghiên cứu trong [Boser et al., 1992], [Chang & Lin, 2011], [Osuna et al., 1997], [Platt, 1998] đã chia bài toán quy hoạch toàn phương gốc thành các bài toán con để giải quyết. Nghiên cứu của [Mangasarian, 2001], [Suykens & Vandewalle, 1999] đã thay đổi bài toán quy hoạch toàn phương phức tạp của giải thuật máy học SVM chuẩn về giải hệ phương trình tuyến tính đơn giản hơn. Nghiên cứu của [Liu et al., 1999], [Poulet & Do, 2004] đã đề nghị xây dựng giải thuật học tăng trưởng, chỉ nạp dữ liệu từng phần rồi cập nhật mô hình theo dữ liệu mà không cần nạp toàn bộ tập dữ liệu trong bộ nhớ. Công trình nghiên cứu của [Do & Poulet, 2004], [Do & Poulet, 2006], [Do & Poulet, 2008] đề nghị giải thuật song song để cải thiện tốc độ huấn luyện. [Tong & Koller, 2000], [Do & Poulet, 2005] đề nghị phương pháp chọn tập con dữ liệu thay vì phải học trên toàn bộ tập dữ liệu gốc. [Do & Fekete, 2007] kết hợp boosting [Freund & Schapire, 1999], arcing [Breiman, 1997] để cải thiện tốc độ xây dựng mô hình SVM chỉ tập trung vào những mẫu khó phân lớp.

Nghiên cứu của chúng tôi trong bài viết này nhằm phát triển từ ý tưởng sử dụng giải thuật giảm gradient ngẫu nhiên (Stochastic Gradient Descent - SGD) để giải trực tiếp vấn đề tối ưu của máy học SVM, được đề xuất bởi [Bottou & Bousquet, 2008], [Shalev-Shwartz et al., 2007] và [Cotter et al., 2011]. Tuy nhiên, vấn đề tối ưu của máy học SVM có hàm *hinge loss* không khả vi là nguyên nhân ảnh hưởng đến hiệu quả của giải thuật SGD. Chúng tôi đề xuất thay thế hàm *hinge loss* bằng các hàm xấp xỉ, khả vi của *hinge loss* (gọi là hàm *alpha-smoothing* hay hàm *logit*) để cải tiến tốc độ hội tụ của giải thuật SGD. Kết quả thực nghiệm trên 2 tập dữ liệu văn bản lớn RCV1 [Bottou & Bousquet, 2008], twitter [Go et al., 2009] cho thấy hiệu quả của đề xuất sử dụng hàm xấp xỉ so với hàm *hinge loss*.

Phần tiếp theo của bài được tổ chức như sau. Phần II sẽ trình bày tóm tắt về máy học SVM, giải thuật SGD sử dụng trong SVM và thay thế hàm *hinge loss* bằng các hàm xấp xỉ khả vi, cải tiến tốc độ hội tụ của giải thuật SGD. Kết quả chạy thử nghiệm sẽ được trình bày trong phần III trước khi kết thúc bằng kết luận và hướng phát triển.

II. GIẢI THUẬT GIẢM GRADIENT NGẪU NHIÊN CHO VẤN ĐỀ PHÂN LỚP CỦA MÁY HỌC SVM

A. Máy học SVM cho vấn đề phân lớp

Xét ví dụ phân lớp nhị phân tuyến tính đơn giản được mô tả như Hình 1. Cho m phần tử $x_1, x_2, \ldots, x_m$ trong không gian n chiều (thuộc tính) với nhãn (lớp) của các phần tử tương ứng là $y_1, y_2, \ldots, y_m$ có giá trị 1 (lớp dương) hoặc giá trị -1 (lớp âm). Nhãn $y_i = 1$ khi x_i thuộc lớp $+1$ (lớp dương, lớp chúng ta quan tâm) và $y_i = -1$, nếu x_i thuộc lớp -1 (lớp âm hay các lớp còn lại).

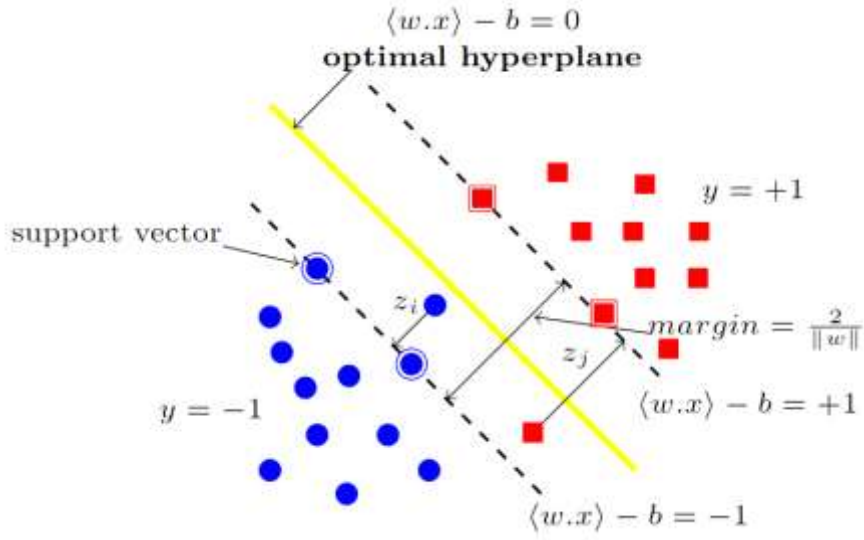

Hình 1. Phân lớp tuyến tính với máy học SVM

Giải thuật máy học SVM [Vapnik, 1995] tìm siêu phẳng tối ưu (xác định bởi véctơ pháp tuyến *w* và độ lệch của siêu phẳng với gốc tọa độ *b*) để tách dữ liệu ra 2 lớp. Máy học SVM tìm siêu phẳng cách xa 2 lớp nhất (siêu phẳng tối ưu) dựa trên 2 siêu phẳng hỗ trợ song song của 2 lớp. Siêu phẳng hỗ trợ của lớp *+1* ($w.x - b = +1$) là siêu phẳng mà các phần tử x_p thuộc lớp $y_p = +1$ nằm về phía bên phải của nó, tức là: $w.x_p - b \geq +1$. Tương tự, siêu phẳng hỗ trợ của lớp *-1* ($w.x - b = -1$) là siêu phẳng mà các phần tử x_n thuộc lớp $y_n = -1$ nằm về phía bên trái siêu phẳng hỗ trợ lớp *-1*, tức là: $w.x_n - b \leq -1$. Những phần tử nằm ngược phía với siêu phẳng hỗ trợ được coi như lỗi. Khoảng cách lỗi được biểu diễn bởi $z_i \geq 0$ (với x_i nằm đúng phía của siêu phẳng hỗ trợ của nó thì khoảng cách lỗi tương ứng $z_i = 0$, còn ngược lại thì $z_i > 0$ là khoảng cách từ điểm x_i đến siêu phẳng hỗ trợ tương ứng của nó). Khoảng cách giữa 2 siêu phẳng hỗ trợ được gọi là lề = $2/\|w\|$, trong đó $\|w\|$ là độ lớn (2-norm) của pháp véctơ *w*. Siêu phẳng tối ưu (nằm giữa 2 siêu phẳng hỗ trợ) cần tìm phải thỏa 2 tiêu chí là cực đại hóa lề (lề càng lớn, mô hình phân lớp càng an toàn) và cực tiểu hóa lỗi. Vấn đề tìm siêu phẳng tối ưu của giải thuật SVM dẫn đến việc giải bài toán quy hoạch toàn phương (1):

$$\begin{aligned} &\min\ \Psi(w, b, z) = (1/2)\ ||w||^2 + c \sum_{i=1}^{m} z_i \\ &\qquad s.t. \\ &y_i(w.x_i - b) + z_i \geq 1 \\ &z_i \geq 0 \quad (i=1,m) \end{aligned} \tag{1}$$

hằng số c > 0 được sử dụng để điều chỉnh sự dung hòa giữa độ rộng lề và cực tiểu lỗi

Giải bài toán quy hoạch toàn phương (1), thu được (*w*, *b*). Mô hình SVM thực hiện phân lớp phần tử *x* dựa vào biểu thức:

$$predict(x) = sign(w.x - b) \tag{2}$$

Mặc dù giải thuật SVM cơ bản chỉ giải quyết được bài toán phân lớp tuyến tính, máy học SVM vẫn có thể sử dụng các hàm nhân khác nhau để giải quyết lớp các bài toán phân lớp phi tuyến [Cristianini & Shawe-Taylor, 2000].

SVM là mô hình phân lớp hiệu quả cho các tập dữ liệu có số chiều lớn [Wu & Kumar, 2009]. SVM đã được áp dụng thành công trong rất nhiều ứng dụng như nhận dạng mặt người, phân loại văn bản, phân loại bệnh ung thư (tham khảo tại [Guyon, 1999]).

Nghiên cứu [Platt, 1998] chỉ ra rằng các giải thuật huấn luyện được đề xuất trong [Boser et al., 1992], [Chang & Lin, 2011], [Osuna et al., 1997], [Platt, 1998] có độ phức tạp tính toán lời giải bài toán quy hoạch toàn phương (1) tối thiểu là $O(m^2)$ trong đó *m* là số lượng phần tử được dùng để huấn luyện. Điều này làm cho giải thuật SVM không phù hợp với dữ liệu lớn.

B. Giải thuật giảm gradient (GD)

Một cài đặt cho giải thuật SVM dựa trên phương pháp giảm gradient (Gradient Descent – GD, tham khảo [Boyd & Vandenberghe, 2004]), có độ phức tạp tuyến tính với số phần tử dữ liệu. Để đơn giản, người ta không xét độ lệch *b* ở đây. Các ràng buộc trong bài toán quy hoạch toàn phương (1) có thể được viết lại như sau:

$$z_i \geq 1 - y_i(w.x_i) \quad (3)$$

$$z_i \geq 0 \qquad (i=1,m) \quad (4)$$

Các ràng buộc (3), (4) có thể được viết ngắn gọn như (5):

$$z_i = max\{0, 1 - y_i(w.x_i)\} \quad (5)$$

Bằng cách thay thế z_i từ (5) vào hàm mục tiêu của (1), việc tìm siêu phẳng tối ưu của SVM có thể được viết lại như vấn đề (6):

$$min\ \Psi(w, x, y) = (\lambda/2)\ ||w||^2 + (1/m) \sum_{i=1}^{m} \max\{0, 1 - y_i(w.x_i)\} \quad (6)$$

Phương pháp giảm gradient (GD) thực hiện tối ưu vấn đề (6) bằng cách cập nhật w tại lần lặp thứ $(t+1)$ dựa trên $\nabla_w \Psi(w_t)$ (gradient của hàm Ψ theo w của lần lặp thứ t), với tốc độ học η_t, như trong (7):

$$w_{t+1} = w_t - (\eta_t / m) \sum_{i=1}^{m} \nabla_w \psi(w_t, x_i, y_i) \quad (7)$$

[Cotter et al., 2011] cũng đề xuất một cách cài đặt dựa trên phương pháp giảm gradient sử dụng tập con ngẫu nhiên để cập nhật w tạo mỗi lần lặp, tăng tốc độ hội tụ đến lời giải nhanh hơn phương pháp giảm gradient.

Mặc dù mỗi lần lặp, phương pháp giảm gradient cập nhật w rất đơn giản, nhưng tốc độ hội tụ của giải thuật giảm gradient chậm so với phương pháp lặp Newton [Boyd & Vandenberghe, 2004].

Đại lượng lỗi $z_i = max\{0, 1 - y_i(w.x_i)\}$ trong vấn đề tối ưu (6) của máy học SVM thường được gọi là hàm lỗi *hinge loss* được viết dưới dạng:

$$L^{hinge}(x) = max\{0, 1 - x\} \quad (8)$$

Chú ý rằng hàm *hinge loss* không khả vi tại $y_i(w.x_i)=1$. Điều này ảnh hưởng đến tốc độ hội tụ của giải thuật giảm gradient.

Để khắc phục được vấn đề này, các giải pháp phổ biến có thể là: sử dụng phương pháp giảm subgradient hoặc thay thế hàm lỗi xấp xỉ khả vi của *hinge loss*.

Giải thuật giảm gradient ngẫu nhiên (SGD) của [Bottou & Boussquet, 2008], [Shalev-Shwartz et al., 2007] thực hiện đơn giản bước cập nhật w_{t+1} dựa trên subgradient chỉ sử dụng một phần tử ngẫu nhiên (x_t, y_t) tại mỗi lần lặp:

$$w_{t+1} = w_t - \eta_t \nabla_w \psi(w_t, x_t, y_t) \quad (9)$$

[Bottou & Bousquet, 2008], [Shalev-Shwartz et al., 2007] chứng minh rằng phương pháp giảm gradient ngẫu nhiên có độ phức tạp tuyến tính với số phần tử dữ liệu.

C. Hàm xấp xỉ khả vi của hinge loss

Chúng tôi đề xuất thay thế hàm *hinge loss* không khả vi bằng các hàm xấp xỉ khả vi để có thể sử dụng trong giải thuật giảm gradient cho vấn đề phân lớp của SVM. Trong nghiên cứu của [Rennie, 2004], hàm xấp xỉ khả vi của *hinge loss* cần có tính chất quan trọng tương tự của hàm *hinge loss* của mô hình SVM để đảm được lề (margin) bằng 1. Nghĩa là hàm xấp xỉ bằng 0 khi $x \geq 1$; có hệ số góc là hằng số âm khi $x \leq 0$; phải trơn vị trí chuyển từ hệ số góc bằng 0 sang hệ số góc âm có chuyển khi $0 < x < 1$.

Dựa trên các yêu cầu trên, chúng tôi đề xuất hàm xấp xỉ khả vi *alpha-smoothing* của *hinge loss*, sử dụng tham số α (là số nguyên lớn hơn 1), được định nghĩa như sau:

$$L_\alpha(x) = \begin{cases} \dfrac{\alpha - 1}{\alpha} - x & if\ (x \leq 0) \\ \dfrac{x^\alpha}{\alpha} - x + \dfrac{\alpha - 1}{\alpha} & if\ (0 < x < 1) \\ 0 & if\ (x \geq 1) \end{cases} \quad (10)$$

Ngoài ra, hàm *logistic loss* (*logit*) là hàm xấp xỉ khả vi khác của *hinge loss* cũng thỏa mãn các yêu cầu trên, nên có thể được sử dụng để thay thế cho *hinge loss*. Hàm *logit* có dạng như sau:

$$L^{logit}(x) = log(1 + e^{-x}) \quad (11)$$

Hình 2 là đồ thị của hàm *hinge loss* so với các hàm xấp xỉ khả vi như *logit loss* và hàm *alpha-smoothing* (với các giá trị tham số $\alpha = 2$ và $\alpha = 4$).

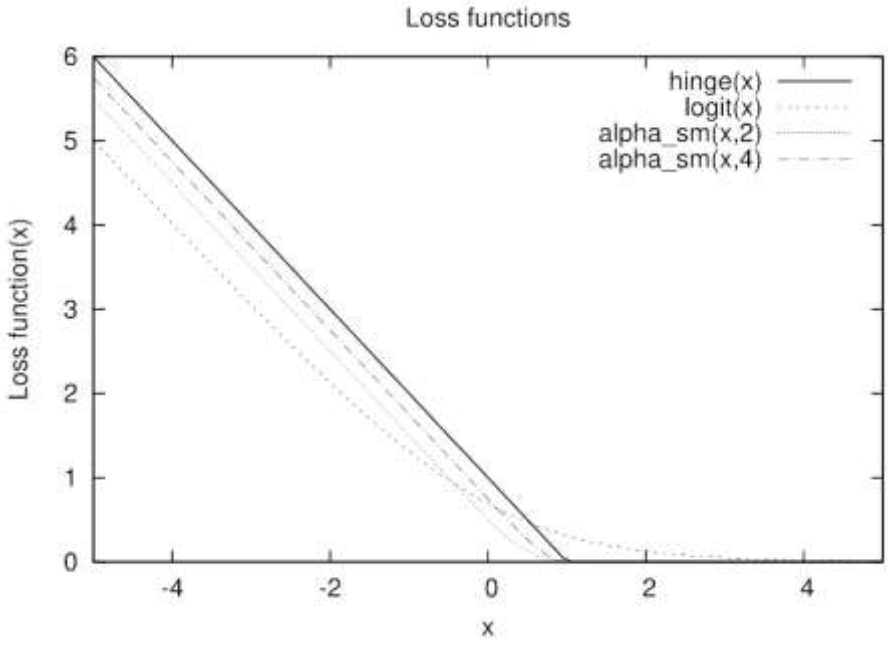

Hình 2. So sánh hàm hinge loss với các hàm xấp xỉ khả vi alpha-smoothing, logit loss

Quan sát đồ thị trên Hình 2, chúng ta có thể thấy rằng các hàm *logit loss* là hàm trơn nhất. Tuy nhiên hàm *alpha-smoothing* cũng đủ trơn và vẫn duy trì được tính chất thưa trong lời giải như hàm *hinge loss*. Hàm *alpha-smoothing* trơn nhất khi giá trị tham số $\alpha = 2$ (gần với *logit loss*), khi tăng giá trị $\alpha = 4$ hàm tiến gần đến *hinge loss*.

Từ khi thay thế hàm *hinge loss* (8) trong (6) và (7) bằng các hàm xấp xỉ khả vi, chúng ta có thể kết hợp với giải thuật giảm gradient được đề xuất bởi [Cotter et al., 2011], sử dụng tập con ngẫu nhiên dữ liệu để cập nhật w ở mỗi lần lặp. Giải thuật SVM-SGD có độ phức tạp tuyến tính với số phần tử của tập dữ liệu học, có thể phân lớp nhanh các tập dữ liệu có số phần tử và số chiều rất lớn.

III. KẾT QUẢ THỰC NGHIỆM

Chúng tôi tiến hành đánh giá hiệu quả của máy học SVM-SGD sử dụng 2 hàm xấp xỉ khả vi của *hinge loss* được giải trực tiếp bởi SGD. Chúng tôi đã cài đặt giải thuật SVM-SGD sử dụng 2 hàm xấp xỉ khả vi (*alpha-smooth, logit loss*) bằng ngôn ngữ lập trình C/C++. Ngoài ra, chúng tôi cũng cần so sánh với SVM-SGD gốc sử dụng *hinge loss* [Bottou & Boussquet, 2008], [Shalev-Shwartz et al., 2007]. Tất cả các giải thuật đều được thực hiện trên một máy tính cá nhân (Intel 3GHz, 4GB RAM) chạy hệ điều hành Linux (Fedora Core 20).

A. Chuẩn bị tập dữ liệu

Chúng tôi sử dụng 2 tập dữ liệu văn bản lớn để làm thực nghiệm. Tập RCV1 được tiền xử lý bởi [Bottou & Boussquet, 2008] theo mô hình túi từ (bag-of-words), bao gồm *781265* văn bản cho tập huấn luyện và *23149* văn bản cho tập kiểm tra, với *47152* từ, được gán nhãn *±1*.

Tập dữ liệu twitter được lấy từ [Go et al., 2009], bao gồm *1600000* ý kiến (*800000* thuộc lớp dương và *800000* thuộc lớp âm). Chúng tôi sử dụng công cụ BoW [McCallum, 1998] để tiền xử lý và biểu diễn các ý kiến theo mô hình túi từ thu được *244895* từ khác nhau. Sau đó chúng tôi chia ngẫu nhiên *1066667* ý kiến cho tập huấn luyện và *533333* cho tập kiểm tra.

B. Kết quả phân lớp

Để so sánh tốc độ hội tụ của SVM-SGD sử dụng hàm *hinge loss* (*hinge*), *alpha-smoothing* (*alpha-sm*) và *logit loss* (*logit*), chúng tôi thực hiện huấn luyện các mô hình với *200* epochs, mỗi 10 epochs, theo dõi tỷ lệ lỗi dựa trên tập kiểm tra của các mô hình theo từng 10 epochs. Chúng tôi sử dụng giá trị tham số $\alpha=2$ cho hàm *alpha-smoothing*, đảm bảo đủ trơn để sử dụng giải thuật giảm gradient, với *50000* phần tử ngẫu nhiên được sử dụng để cập nhật w ở mỗi bước lặp của giải thuật SVM-SGD.

Bảng 1. Kết quả phân lớp tập dữ liệu RCV1

Số epochs	Tỷ lệ lỗi (%)		
	SVM-SGD (hinge)	SVM-SGD (alpha-sm)	SVM-SGD (logit)
10	28.84	9.555	10.17
20	15.4	6.454	7.625
30	16.88	5.892	6.67
40	12.98	5.503	6.143
50	13.89	5.404	6.005
60	11.97	5.607	5.728
70	11.92	5.547	5.715
80	11.38	5.465	5.719
90	11.02	5.4	5.594
100	11.19	5.469	5.512
110	10.79	5.387	5.542
120	12.15	5.391	5.491
130	10.41	5.309	5.478
140	10.82	5.322	5.352
150	10.35	5.383	5.538
160	10.54	5.305	5.404
170	17.18	5.179	5.37
180	15.6	5.283	5.426
190	12.6	5.218	5.287
200	13.58	5.201	5.275

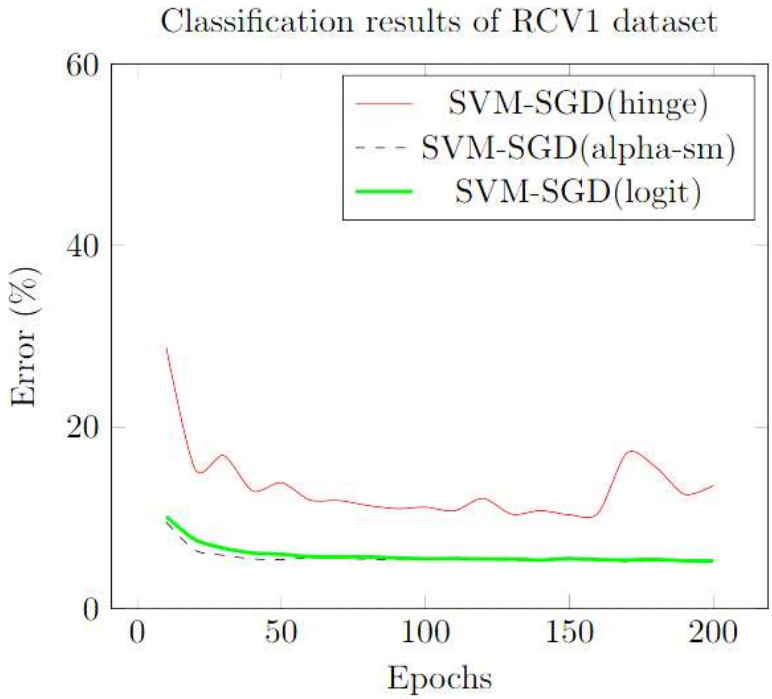

Hình 3. So sánh kết quả phân lớp tập dữ liệu RCV1

Kết quả phân lớp thu được trên tập RCV1 của các mô hình được trình bày trong Bảng 1 và Hình 3. Quan sát đồ thị trong Hình 3, chúng ta có thể thấy rằng SVM-SGD (*alpha-sm*) và SVM-SGD (*logit*) giảm tỷ lệ lỗi phân lớp ổn định khi tăng số epochs huấn luyện của các mô hình. Trong khi đó, SVM-SGD (*hinge*) thì giảm tỷ lệ lỗi không được nhanh và thiếu ổn định khi tăng số lượng epochs. Thời gian huấn luyện 200 epochs của SVM-SGD (*hinge*), SVM-SGD (*alpha-sm*) và SVM-SGD (*logit*) tương ứng là 195, 185 và 235 giây.

Với tập dữ liệu Twitter, kết quả phân lớp thu được từ các mô hình như trong Bảng 2, Hình 4. Quan sát đồ thị, một lần nữa, chúng ta có thể thấy rằng SVM-SGD (*alpha-sm*) và SVM-SGD (*logit*) giảm tỷ lệ lỗi phân lớp rất hiệu quả khi tăng số epochs huấn luyện của các mô hình. Khi tăng số lượng epochs, SVM-SGD (*hinge*) giảm tỷ lệ lỗi phân lớp chậm và không ổn định khi so sánh với 2 mô hình sử dụng hàm xấp xỉ khả vi. Thời gian huấn luyện 200 epochs của SVM-SGD (*hinge*), SVM-SGD (*alpha-sm*) và SVM-SGD (*logit*) tương ứng là 194, 206 và 225 giây.

Bảng 2. Kết quả phân lớp tập dữ liệu Twitter

Số epochs	Tỷ lệ lỗi (%)		
	SVM-SGD (hinge)	SVM-SGD (alpha-sm)	SVM-SGD (logit)
10	36.54	35.42	32.78
20	29.9	34.61	28.38
30	32.11	28.48	26.82
40	30.25	29.74	25.97
50	32.12	27.24	25.39
60	31.77	26.89	25.45
70	32.62	26.83	24.85
80	32.79	25.93	25
90	31.62	25.63	24.55
100	30.77	25.44	24.47
110	31.82	25.37	24.41
120	32.33	25.72	24.41
130	32.07	25.29	24.62
140	36.32	25.04	24.3
150	30.99	25.05	24.43
160	33.13	24.81	24.2
170	35	24.66	24.39
180	30.46	24.74	24.13
190	32.54	24.93	24.06
200	31.42	24.68	24.07

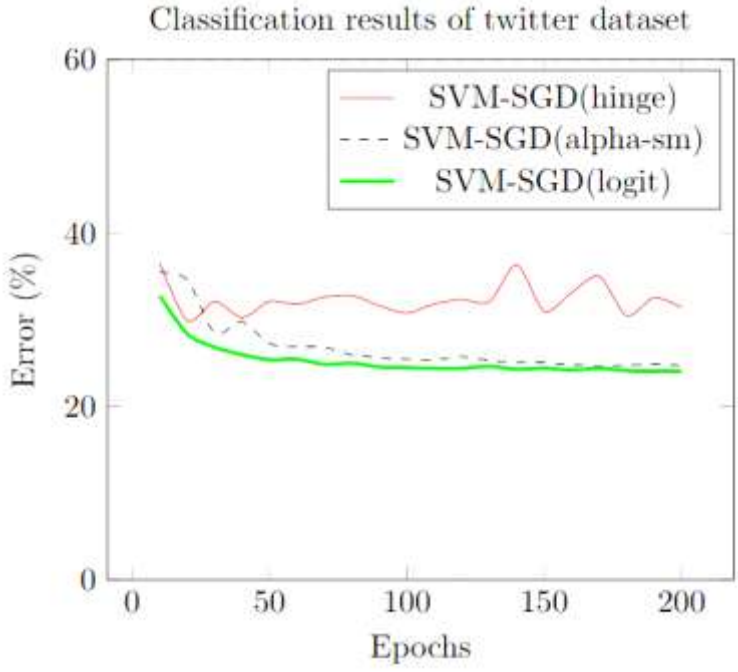

Hình 4. So sánh kết quả phân lớp tập dữ liệu Twitter

Với các kết quả phân lớp này, chúng tôi có thể tin rằng mô hình SVM sử dụng hàm xấp xỉ khả vi của *hinge loss* cho phép cải thiện hiệu quả phân lớp tập dữ liệu lớn khi giải trực tiếp bằng giải thuật SGD.

IV. KẾT LUẬN VÀ HƯỚNG PHÁT TRIỂN

Để máy học SVM có thể phân lớp nhanh, chính xác các tập dữ liệu lớn, giải pháp hiệu quả là sử dụng giải thuật SGD để giải trực tiếp vấn đề tối ưu của mô hình SVM. Tuy nhiên, SVM sử dụng hàm *hinge loss* không khả vi, là nguyên nhân làm ảnh hưởng đến tốc độ hội tụ đến lời giải của SGD. Chúng tôi đã đề xuất thay thế các hàm xấp xỉ khả vi của hinge loss trong mô hình SVM, nhằm cải thiện tốc độ hội tụ của SVM-SGD. Kết quả thực nghiệm trên 2 tập dữ liệu văn bản lớn RCV1, Twitter cho thấy sự hiệu quả của đề xuất. SVM-SGD sử dụng (*alpha-smoothing* hay *logit*) có thể phân lớp hàng triệu văn bản chỉ trong 5 giây (không bao gồm thời gian đọc dữ liệu) trên một máy PC (Intel 3GHz, 4GB RAM) chạy hệ điều hành Linux (Fedora Core 20).

Trong tương lai, chúng tôi tiếp tục nghiên cứu các hàm xấp xỉ khả vi khác của *hinge loss*. Chúng tôi sẽ phát triển giải thuật SVM-SGD song song cho phép tăng tốc quá trình thực thi trên máy tính có nhiều bộ xử lý, nhóm hay lưới máy tính.

TÀI LIỆU THAM KHẢO

[1] Boser, B., Guyon, I., Vapnik, V., "An training algorithm for optimal margin classifiers", In proceedings of 5th ACM Annual Workshop on Computational Learning Theory, pp.144-152, 1992.

[2] Bottou, L., Bousquet, O.: "The tradeoffs of large scale learning", In Advances in Neural Information Processing Systems (20):161-168, 2008.

[3] Boyd, S. and Vandenberghe, L.: "*Convex Optimization*", Cambridge University Press, 2004.

[4] Breiman, L., "Arcing classifiers", *The Annals of Statistics*, vol. 26, no. 3, pp.801-849, 1998.

[5] Chang, C. C., Lin, C. J., "LIBSVM: a library for support vector machines", *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 27, pp.1-27, 2011 http://www.csie.ntu.edu.tw/~cjlin/libsvm.

[6] Cotter, A., Shamir, O., Srebro, N., and Sridharan, K.: "Better Mini-Batch Algorithms via Accelerated Gradient Methods", NIPS, pp. 1647-1655, 2011.

[7] Cristianini, N., Shawe-Taylor, J., "*An Introduction to Support Vector Machines: And Other Kernel-based Learning Methods*", Cambridge University Press, New York, NY, USA, 2000.

[8] Do, T.N., "Parallel multiclass stochastic gradient descent algorithms for classifying million images with very-high-dimensional signatures into thousands classes", *Vietnam J. Computer Science*, vol. 1, no. 2, pp.107-115, 2014.

[9] Do, T.N., Nguyen, V.H., Poulet, F., "Speedup SVM algorithm for massive classification tasks", In Proceedings of ADMA, pp.147-157, 2008.

[10] Do, T.N., Fekete, J.D., "Large scale classification with support vector machine algorithms. In The Sixth International Conference on Machine Learning and Applications, ICMLA 2007, Cincinnati, Ohio, USA, pp.7-12, 2007.

[11] Do, T.N., Poulet, F., "Classifying one billion data with a new distributed svm algorithm", In proceedings of 4th IEEE Intl. Conf. on Computer Science, Research, Innovation and Vision for the Future, IEEE Press, pp.59-66, 2006.

[12] Do, T.N., Poulet, F., "Mining very large datasets with svm and visualization", In proceedings of 7th Intl. Conf. on Entreprise Information Systems, pp.127-134, 2005.

[13] Freund, Y., Schapire, R., "A short introduction to boosting", *Journal of Japanese Society for Artificial Intelligence*, vol. 14, no. 5, pp.771-780, 1999.

[14] Go, A., Bhayani, R., Huang, L.: "Twitter sentiment", May 12th 2014 (accessed date), http://help.sentiment140.com.

[15] Guyon, I., Web page on svm applications, 1999, http://www.clopinet.com/isabelle/Projects/SVM/applist.html.

[16] Liu H., Syed, N. and K. Sung.: "Incremental learning with support vector machines", ACM SIGKDD, 1999.

[17] McCallum, A.: "Bow: A Toolkit for Statistical Language Modeling, Text Retrieval, Classification and Clustering", 1998. http://www-2.cs.cmu.edu/~mccallum/bow.

[18] Mangasarian O.L.: "Mathematical Programming for Support Vector Machines", INRIA Rocquencourt, France July 17, 2001.

[19] Osuna, E., Freund, R., Girosi, F., "An improved training algorithm for support vector machines", *Neural Networks for Signal Processing VII*, J. Principe, L. Gile, N. Morgan, and E. Wilson Eds, pp.276-285, 1997.

[20] Platt J.: Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines, Microsoft Research Technical Report MSR-TR-98-14, 1998.

[21] Poulet, F., Do, T.N., "Mining very large datasets with support vector machine algorithms", *Enterprise Information Systems* V, O. Camp, J. Filipe, S. Hammoudi and M. Piattini Eds., pp.177-184, 2004.

[22] Rennie, J.D.M.: "Derivation of the f-measure", http://people.csail.mit.edu/jrennie/writing (February 2004).

[23] Shalev-Shwartz, S., Singer, Y., Srebro, N., "Pegasos: Primal estimated sub-gradient solver for svm", In Proceedings of the Twenty-Fourth International Conference Machine Learning, ACM, pp.807-814, 2007.

[24] Suykens, J., Vandewalle, J. "Least squares support vector machines classifiers", *Neural Processing Letters*, vol. 9, no. 3, pp.293–300, 1999.

[25] Tong, S., Koller, D., "Support vector machine active learning with applications to text classification", In proceedings of the 17th Intl. Conf. on Machine Learning, ACM, pp. 999-1006, 2000.

[26] Vapnik, V.: "*The Nature of Statistical Learning Theory*", Springer-Verlag, 1995.

[27] Wu X. and Kumar V.: "*Top 10 Algorithms in Data Mining*", Chapman & Hall/CRC, 2009.

EFFICIENTLY CLASSIFYING VERY LARGE DATASETS WITH STOCHASTIC GRADIENT DESCENT

Thanh Nghi Do, The Phi Pham

ABSTRACT*— In this paper, we present the support vector machines algorithm using the stochastic gradient descent for classifying very large datasets. To reach to the sparsity in the solution, the support vector machines algorithm uses the hinge loss in classification tasks. Thus, the direct optimization using the stochastic gradient descent is difficult due to the differentiation of the hinge loss. Our proposal is to substitute the hinge loss used in the problem formula of the support vector machines algorithm by the smooth ones to improve the convergence rate of the stochastic gradient descent. The numerical test results on two large textual datasets (RCV1, twitter) show that our proposal is more efficient than the usual hinge loss.*