

XÁC ĐỊNH HEMATOCRIT SỬ DỤNG MẠNG NEURAL ĐƯỢC HUẤN LUYỆN ONLINE DỰA TRÊN MÁY HỌC CỰC ĐỘ

HUỲNH TRUNG HIẾU, HỒ ĐẮC QUÁN

Khoa Công nghệ Thông tin, Đại học Công nghiệp Tp. HCM

Tóm tắt. Hematocrit (HCT) là tỉ lệ phần trăm về thể tích của hồng cầu so với thể tích máu. Đây là yếu tố ảnh hưởng rất lớn đến quá trình đo glucose sử dụng các thiết bị cầm tay. Trong bài báo này các tác giả trình bày một cách tiếp cận mới để đo HCT từ cung dòng điện được tạo ra bởi phản ứng hóa học trong quá trình đo glucose của các thiết bị cầm tay. Phương pháp đề xuất dựa trên mạng neural nhân tạo được huấn luyện online dựa trên máy học cực độ (Extreme Learning Machine - ELM). Những kết quả thực nghiệm cho thấy, phương pháp đề nghị cho kết quả khả quan khi so sánh với các phương pháp trước.

Từ khóa. Hematocrit; mạng nơon; máy học cực độ; huấn luyện online; đo glucose.

Abstract. Hematocrit (HCT) is the volume percentage of red blood cells in the whole blood. This is the most highly influencing factor in glucose measurement using handheld devices. In this paper, we present a new approach to estimate hematocrit from the transduced current curve which is produced by chemical reaction on electrochemical biosensors used in glucose measurement. Our method utilizes the single-hidden layer feedforward neural network trained by online sequential extreme learning machine. The experimental results are given to show high level of accuracy of the proposed method.

Key words. Hematocrit; neural network, extreme learning machine; online sequential training; glucose measurement.

1. GIỚI THIỆU

Hematocrit (HCT) là một trong những thông số quan trọng trong y học chẳng hạn như phẫu thuật và lọc máu (hemodialysis) [1-2]. Nó cũng được xem là dấu hiệu của bệnh thiếu máu (anemia, khả năng vận chuyển Oxy trong máy sẽ giảm) nếu HCT ở mức thấp. HCT mức cao là dấu hiệu của bệnh polycythaemia. Ngoài ra, đây cũng là yếu tố ảnh hưởng lớn nhất đến kết quả đo glucose bằng các thiết bị cầm tay [3-5]. Giá trị glucose đo được có xu hướng lệch lớn hơn giá trị đúng tại HCT ở mức thấp và lệch thấp hơn giá trị đúng tại HCT ở mức cao. Việc xác định giá trị HCT có thể thực hiện bằng phương pháp ly tâm, các thiết bị phân tích chuyên dụng, dielectric spectroscopy [6], hoặc 1 số kỹ thuật khác. Tuy nhiên hầu hết các phương pháp trên khá phức tạp và/hoặc yêu cầu 1 thiết bị chuyên dụng, đặc biệt là không thể áp dụng được trong các thiết bị cầm tay.

*Bài báo được thực hiện với sự hỗ trợ từ trường Đại học Quốc gia Chonnam, Hàn Quốc, Viện nghiên cứu BioIT, và Công ty GlucoDr

Việc xác định giá trị HCT từ cung dòng điện (Transduced Current Curve) sử dụng mạng neural truyền thẳng đã được đề xuất trong các bài báo trước [7]. Một mạng neural truyền thẳng tổng quát bao gồm một lớp nhập, các lớp ẩn và một lớp xuất. Tuy nhiên, người ta đã chứng minh được rằng, mạng truyền thẳng với 1 lớp ẩn (Single Hidden Layer Feedforward Neural Network-SLFN) có thể xấp xỉ 1 hàm bất kỳ và biên quyết định với hình dạng bất kỳ [8] nếu hàm kích hoạt được chọn 1 cách thích hợp. Do đó, trong nghiên cứu này sẽ tập trung vào mạng neural truyền thẳng 1 lớp ẩn (SLFN).

Thông thường, huấn luyện mạng neural dựa trên tiếp cận giảm gradient, một trong những thuật toán huấn luyện phổ biến cho mạng neural dựa trên tiếp cận giảm gradient là thuật toán lan truyền ngược (Backpropagation), trong đó các trọng số của mạng được cập nhật từ lớp xuất đến lớp nhập. Thuật toán này thường hội tụ chậm, nó cũng dễ dàng gặp phải vấn đề tối ưu cục bộ (Local Minima) hay quá khớp (Overfitting). Mặc dù có nhiều cải tiến, nhưng đến thời điểm này hầu hết các thuật toán huấn luyện dựa trên giảm gradient đều khá chậm do yêu cầu nhiều bước lặp. Một thuật toán huấn luyện hiệu quả được đề xuất gần đây trong huấn luyện SLFN là máy học cực độ (Extreme Learning Machine -ELM) [9-12]. Trong ELM, các trọng số ở lớp nhập và các độ dịch ở lớp ẩn được gán các giá trị ngẫu nhiên, sau đó trọng số lớp xuất được xác định bởi phép tính ma trận đơn giản dựa trên nghịch đảo của ma trận lớp ẩn. Thuật toán này có thể khắc phục một số nhược điểm của thuật toán lan truyền ngược như tối ưu cục bộ, tốc độ học, epochs...

Trong các nghiên cứu trước, SLFN dùng trong xác định HCT được huấn luyện dạng offline. Trong bài báo này nhóm tác giả tiếp tục phát triển phương pháp xác định HCT từ cung dòng điện sử dụng SLFN được huấn luyện dạng online. Các đặc trưng đầu vào (Input Features) cho mạng neural được lấy mẫu từ cung dòng điện được tạo ra do sự di chuyển các ion đến điện cực. Các ion này được tạo ra do phản ứng hóa học với enzyme trong quá trình đo glucose sử dụng glucose sensor (Electrochemical Glucose Biosensor).


Bố cục của bài báo được tổ chức: Mục 2 trình bày thuật toán huấn luyện online cho SLFN dựa trên máy học cực độ (ELM). Phương pháp xác định HCT sử dụng ELM được huấn luyện online được mô tả trong Mục 3, Mục 4 trình bày các kết quả thực nghiệm. Và cuối cùng là kết luận.

2. HUẤN LUYỆN ONLINE CHO MÁY HỌC CỰC ĐỘ

Mạng neural đã và đang được sử dụng rất phổ biến trong nhiều ứng dụng khác nhau [13]. Có nhiều kiến trúc mạng khác nhau đã và đang được nghiên cứu và phát triển. Tuy nhiên người ta đã chứng minh được rằng một mạng neural truyền thẳng với lớp ẩn đơn có thể tạo ra các biên phân loại với hình dạng bất kỳ hoặc nó có thể xấp xỉ hàm bất kỳ nếu hàm kích hoạt được chọn một cách thích hợp [8]. Do đó, mạng một lớp ẩn đã và đang được ứng dụng phổ biến nhất. Kiến trúc tiêu biểu của mạng neural một lớp ẩn với d nút ở lớp nhập, N nút ở lớp ẩn và C nút ở lớp xuất có thể được mô tả như trong Hình 1.

Giả sử $\mathbf{w}_m = [w_{m1}, w_{m2}, \dots, w_{md}]$ là vector trọng số của các kết nối từ lớp nhập đến nút ẩn thứ m , b_m là độ dịch (bias) của nó và $\mathbf{a}_i = [a_{i1}, a_{i2}, \dots, a_{iN}]^T$ là vector trọng số của các kết nối từ lớp ẩn đến nút xuất thứ i thì vector ngõ xuất \mathbf{o}_j tương ứng với vector nhập \mathbf{x}_j được xác định bởi

$$o_{ji} = \sum_{m=1}^N a_{im} f(\mathbf{w}_m \cdot \mathbf{x}_j + b_m), \quad \mathbf{x} \in IR^d, \quad (1)$$



Hình 1. Kiến trúc tiêu biểu của mạng neural một lớp ẩn (SLFN)

trong đó $f(\cdot)$ là hàm kích hoạt của các nút ẩn, $\mathbf{w}_m \cdot \mathbf{x} = \langle \mathbf{w}_m, \mathbf{x} \rangle$ là tích vô hướng giữa 2 vector \mathbf{w}_m và \mathbf{x} .

Cho tập mẫu $\mathbf{S} = \{(\mathbf{x}_j, \mathbf{t}_j) | j = 1, 2, \dots, n\}$, mục đích chính của quá trình huấn luyện mạng là tìm ra các trọng số, bao gồm \mathbf{w} , \mathbf{a} và b để tối ưu một hàm mục tiêu nào đó. Thông thường, hàm mục tiêu được chọn là bậc 2 được định nghĩa như sau

$$E = \sum_{j=1}^n \|\mathbf{o}_j - \mathbf{t}_j\|^2 = \sum_{j=1}^n \left\| \sum_{m=1}^N \mathbf{a}_{*m} f(\mathbf{w}_m \cdot \mathbf{x}_j + b_m) - \mathbf{t}_j \right\|^2. \quad (2)$$

Một trong những thuật toán huấn luyện hiệu quả được phát triển gần đây là máy học cực độ hay ELM (Extreme Learning Machine). Nó dựa trên ý tưởng là thay vì xác định tất cả các trọng số mạng bằng các quá trình lặp lại, trọng số lớp nhập và độ dịch có thể được chọn ngẫu nhiên và trọng số lớp xuất được xác định bằng các bước đơn. Rõ ràng, một mạng với N nút ẩn có thể xấp xỉ N mẫu với lỗi bằng 0, nghĩa là tồn tại các trọng số \mathbf{w} , \mathbf{a} và b sao cho

$$\mathbf{t}_j = \sum_{m=1}^N \mathbf{a}_{*m} f(\mathbf{w}_m \cdot \mathbf{x}_j + b_m), \quad j = 1, 2, \dots, N. \quad (3)$$

Phương trình này có thể được viết lại như sau

$$\mathbf{H}\mathbf{A} = \mathbf{T}, \quad (4)$$

trong đó \mathbf{H} còn được gọi là ma trận ngõ xuất lớp ẩn, $\mathbf{T} = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_n]^T$ và $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N]$. Trong [9], các tác giả đã chứng minh được rằng ma trận \mathbf{H} là khả đảo nếu số mẫu trong tập huấn luyện bằng số nút ẩn và hàm kích hoạt khả vi. Trong trường hợp số nút ẩn nhỏ hơn số mẫu huấn luyện thì ma trận trọng số xuất \mathbf{A} sẽ được xác định bởi ma trận giả đảo của \mathbf{H} với sự chọn lựa ngẫu nhiên của trọng số nhập và độ dịch. Các kết quả này đã được chứng minh trong [9]. Như vậy, thuật giải ELM có thể được tóm tắt như sau

- Gán các giá trị ngẫu nhiên cho trọng số nhập và độ dịch (bias) các nút ẩn.
- Tính ma trận ngõ xuất lớp ẩn \mathbf{H} .
- Xác định trọng số xuất bằng cách sử dụng phương trình sau



$$\hat{\mathbf{A}} = \mathbf{H}^\dagger \mathbf{T}, \quad (5)$$

trong đó, \mathbf{H}^\dagger được gọi là ma trận giả đảo của \mathbf{H} . Như vậy, các trọng số của mạng có thể được xác định bởi những bước đơn giản và không cần sự tính toán bởi các bước lặp như các thuật toán giảm gradient. Nó có thể khắc phục những nhược điểm như chọn lựa hệ số tốc độ học, epochs, khởi động giá trị ban đầu,... Đặc biệt, thuật toán này cho thời gian huấn luyện rất nhanh.

3. XÁC ĐỊNH HCT SỬ DỤNG ONLINE ELM

3.1. Các đặc trưng ngõ nhập


Trong nghiên cứu này, các đặc trưng ngõ vào cho mạng neural là các điểm dữ liệu được lấy mẫu từ cung dòng điện được tạo ra do phản ứng hóa học xảy ra trong quá trình đo glucose sử dụng cảm biến sinh học điện hóa (Electrochemical Biosensor). Trong quá trình đo glucose sử dụng cảm biến sinh học điện hóa (Electrochemical Biosensor - được các thiết bị cầm tay sử dụng), glucose oxydase enzyme trong bộ cảm biến sinh học (GOD) xúc tác phản ứng oxy hóa glucose tạo ra gluconic axit và hydrogen peroxide (H_2O_2). Sau đó, nó được oxy hóa trở lại trạng thái ban đầu và giải phóng electron. Electron di chuyển giữa 2 điện cực của tạo thành dòng điện.



Hình 2. Cung dòng điện trong 14 giây đầu tiên

Một cung dòng điện được tạo ra trong 14 giây đầu tiên được chỉ ra trong Hình 2. Rõ ràng, dữ liệu trong 8 giây đầu tiên không chứa nhiều thông tin cho việc tính HCT, nó có thể xem là “thời gian ủ” (Incubation Time) để chờ phản ứng hóa học thực hiện. Trong nghiên cứu này, ta sẽ tập trung vào phần thứ 2 của cung dòng điện ở 6 giây sau. Trong đoạn thời gian 6 giây sau, cung dòng điện được lấy mẫu với tần số 10Hz tạo thành các điểm dữ liệu như trình bày trong Hình 3. Như vậy, sẽ có 59 điểm dữ liệu được sử dụng là các đặc trưng ngõ vào cho mạng neural để xác định HCT. Gọi mẫu thứ j là $\mathbf{x}_j = [x_{j1}, x_{j2}, \dots, x_{j59}]$.

Sử dụng SLFN để xác định HCT với vector đặc trưng ngõ vào \mathbf{x} đã được đề nghị trong 1 số nghiên cứu trước của chúng tôi [7], tuy nhiên ở các bài báo trước, mạng neural được huấn luyện dạng offline. Trong bài báo này tác giả phát triển ứng dụng mạng neural huấn luyện dạng online trong xác định HCT.



Hình 3. Các điểm dữ liệu được lấy mẫu trên cung dòng điện

3.2. Thuật giải huấn luyện cho SLFN

Dựa trên ý tưởng của ELM, một tiếp cận huấn luyện online được gọi là máy học cực độ online (Online Sequential Extreme Learning Machine, OS-ELM) đã được đưa ra bởi Liang và các cộng sự [14], trong đó giả thiết rằng $\mathbf{H}^T \mathbf{H}$ là nonsingular, giả đảo của \mathbf{H} được xác định bởi

$$\mathbf{H}^\dagger = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T. \quad (6)$$

Thay vào (5), ta có

$$\hat{\mathbf{A}} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{T}. \quad (7)$$

Bây giờ, ta bắt đầu tìm luật học trong quá trình huấn luyện online. Bắt đầu với tập dữ liệu huấn luyện $\mathbf{S}_0 = \{(\mathbf{x}_j, \mathbf{t}_j) | j = 1, \dots, n_0\}$, trọng số lớp xuất được xác định bởi

$$\mathbf{A}_0 = \mathbf{L}_0^{-1} \mathbf{H}_0^T \mathbf{T}_0, \quad (8)$$

trong đó $\mathbf{L}_0 = \mathbf{H}_0^T \mathbf{T}_0$, $\mathbf{T}_0 = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_{n_0}]^T$ và $\mathbf{H}_0 = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_{n_0}]^T$. Đối với tập huấn luyện gồm n_1 mẫu tiếp theo, $\mathbf{S}_1 = \{(\mathbf{x}_j, \mathbf{t}_j) | j = n_0 + 1, \dots, n_0 + n_1\}$, trọng số lớp xuất sẽ được tính bởi

$$\mathbf{A}_1 = \left(\begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix} \right)^{-1} \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix} = \mathbf{L}_1^{-1} \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix}, \quad (9)$$

với $\mathbf{L}_1 = \mathbf{L}_0 + \mathbf{H}_1^T \mathbf{H}_1$, $\mathbf{T}_1 = [\mathbf{t}_{n_0+1}, \mathbf{t}_{n_0+2}, \dots, \mathbf{t}_{n_0+n_1}]^T$ và $\mathbf{H}_1 = [\mathbf{h}_{n_0+1}, \mathbf{h}_{n_0+2}, \dots, \mathbf{h}_{n_0+n_1}]^T$. Hai số hạng cuối của (9) có thể được viết lại là

$$\begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix} = \mathbf{H}_0^T \mathbf{T}_0 + \mathbf{H}_1^T \mathbf{T}_1 = \mathbf{L}_0 \mathbf{A}_0 + \mathbf{H}_1^T \mathbf{T}_1.$$

Khi đó (9) có thể được viết lại

$$\mathbf{A}_1 = \mathbf{L}_1^{-1} (\mathbf{L}_0 \mathbf{A}_0 + \mathbf{H}_1^T \mathbf{T}_1) = \mathbf{A}_0 + \mathbf{L}_1^{-1} \mathbf{H}_1^T (\mathbf{T}_1 - \mathbf{H}_1 \mathbf{A}_0).$$

Trong trường hợp tổng quát với n_k mẫu huấn luyện,

$$\mathbf{S}_k = \{(\mathbf{x}_t, \mathbf{t}_j) | j = \sum_{i=0}^{k-1} n_i + 1, \dots, \sum_{i=0}^k n_i\},$$

trọng số lớp xuất \mathbf{A}_k có thể được cập nhật bởi

$$\mathbf{L}_k = \mathbf{L}_{k-1} + \mathbf{H}_k^T \mathbf{H}_k, \quad (10)$$

$$\mathbf{A}_k = \mathbf{A}_{k-1} + \mathbf{L}_k^{-1} \mathbf{H}_k^T (\mathbf{T}_k - \mathbf{H}_k \mathbf{A}_{k-1}), \quad (11)$$

trong đó

$$\mathbf{T}_k = [\mathbf{t}_{\sum_{i=0}^{k-1} n_i + 1} \mathbf{t}_{\sum_{i=0}^{k-1} n_i + 2} \dots \mathbf{t}_{\sum_{i=0}^k n_i}]^T$$

và

$$\mathbf{H}_k = [\mathbf{h}_{\sum_{i=0}^{k-1} n_i + 1} \mathbf{h}_{\sum_{i=0}^{k-1} n_i + 2} \dots \mathbf{h}_{\sum_{i=0}^k n_i}]^T.$$

Như vậy, thuật toán huấn luyện online có thể được mô tả như sau.

- Giai đoạn khởi tạo:

Ứng với tập huấn luyện khởi tạo $\mathbf{S}_0 = \{(\mathbf{x}_j, \mathbf{t}_j) | j = 1, 2, \dots, n_0\}$ ta thực hiện các bước sau:

- Gán các giá trị ngẫu nhiên cho trọng số lớp nhập \mathbf{w} và độ dịch b .
- Xác định ma trận xuất lớp ẩn \mathbf{H}_0 .
- Xác định ma trận $\mathbf{L}_0 = \mathbf{H}_0^T \mathbf{H}_0$.
- Xác định \mathbf{A}_0 sử dụng công thức (8).

- Giai đoạn cập nhật trọng số:

Ứng với tập mẫu huấn luyện $\mathbf{S}_k = \{(\mathbf{x}_j, \mathbf{t}_j) | j = \sum_{i=0}^{k-1} n_i + 1, \dots, \sum_{i=0}^k n_i\}$ ta thực hiện các

bước sau:

- Xác định ma trận \mathbf{H}_k .
- Xác định ma trận \mathbf{L}_k sử dụng công thức (10).
- Cập nhật ma trận trọng số \mathbf{A}_k sử dụng công thức (11).


4. KẾT QUẢ THỰC NGHIỆM

Dữ liệu trong thực nghiệm của của bài báo được lấy từ 199 mẫu máu của các tình nguyện viên. Mỗi mẫu máu được chia làm 2 phần, phần đầu được dùng để xác định giá trị hematocrit chính xác bằng phương pháp ly tâm, phần thứ 2 được dùng để xác định cung dòng điện như Hình 2. Trong phần 2 của cung dòng điện sau “thời gian ử”, 59 điểm dữ liệu được lấy mẫu với tần số 10Hz. Phân bố giá trị hematocrit chính xác có dạng như Hình 4, với giá trị trung bình là 36.02 và độ lệch là 6.39. Tập dữ liệu sau đó được chia làm 2 phần gồm 40% cho huấn luyện và 60% cho đánh giá (testing). Các đặc trưng ngõ nhập được chuẩn hóa về đoạn $[0, 1]$. Thuật giải được hiện thực trên môi trường Matlab 7.0.

Độ chính xác được đánh giá dựa trên đại lượng RMSE (Root Mean Square Error) được định nghĩa bởi

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (\mathbf{o}_j - \mathbf{t}_j)^2}, \quad (12)$$

trong đó, \mathbf{o}_j là giá trị xuất được xác định từ mạng neural, \mathbf{t}_j là giá trị đo chính xác, và n là số mẫu đánh giá. Kết quả trung bình của 50 lần thử được trình bày trong Bảng 1. Từ Bảng 1 ta



Hình 4. Phân bố của giá trị hematocrit thu thập được

có thể thấy rằng số nút ẩn trong huấn luyện online bằng số nút ẩn trong trường hợp offline, tuy nhiên độ chính xác trong huấn luyện online cao bằng các huấn luyện offline. Chú ý rằng, trường hợp huấn luyện online cho phép ta tiếp tục huấn luyện hệ thống trong quá trình sử dụng để nâng cao hiệu quả.

Bảng 1. So sánh RMSE giữa phương pháp online và offline

Method	Training		Testing		# node
	RMSE	Mean	RMSE	Mean	
ELM (offline)	4.27	10^{-4}	4.92	-0.26	12
OS-ELM (online)	4.35	10^{-4}	4.91	-0.27	12

5. KẾT LUẬN

Hematocrit (HCT) là 1 yếu tố đóng vai trò quan trọng trong y khoa, và đặc biệt là trong quá trình đo glucose bằng các thiết bị cầm tay. Đối với các thiết bị cầm tay do tính thuận tiện và nhỏ gọn của nó, ta không thể đo hematocrit bằng cách sử dụng các phương pháp truyền thống như ly tâm, mà chỉ có thể đo từ cung dòng điện được tạo ra trong quá trình thực hiện phản ứng giữa glucose và enzyme được tráng trên các biosensor. Trong bài báo này, tác giả đã tiếp tục phát triển nghiên cứu sử dụng mạng neural xác định HCT từ cung dòng điện với mạng neural được huấn luyện online. Kết quả thực nghiệm cho thấy với cùng kiến trúc mạng, độ chính xác của huấn luyện online xấp xỉ cách huấn luyện offline. Và với cách huấn luyện online cho phép ta tiếp tục huấn luyện trong quá trình sử dụng từ đó nâng cao hiệu quả của hệ thống. Bước tiếp theo của nghiên cứu này là giảm ảnh hưởng của HCT (được xác định từ cung dòng điện) trong quá trình đo glucose bằng thiết bị cầm tay.

TÀI LIỆU THAM KHẢO

- [1] J. Z. Ma, J. Ebben, H. Xia, and A. J. Collins, Hematocrit level and associated mortality in hemodialysis patients, *J. Amer. Soc. Nephrol.* **10** (1999) 610–619.
- [2] A. Aris, J. M. Padro, J. O. Bonnin, and J. M. Caralps, Prediction of hematocrit changes in open-heart surgery without blood transfusion, *J. Cardiovasc. Surg.* **25** (6) (Nov-Dec. 1984) 545–548.

- [3] R. F. Louie, Z. Tang, D. V. Sutton, J. H. Lee, G. J. Kost, Point of care glucose testing: effects of critical variables, influence of reference instruments, and a modular glucose meter design, *Arch Pathol Lab Med* **124** (2000) 257–266.
- [4] Z. Tang, J. H. Lee, R. F. Louie, G. J. Kost, D. V. Sutton, Effects of different hematocrit levels on glucose measurements with handheld meters for point of care testing, *Arch Pathol Lab Med* **124** (2000) 1135–1140.
- [5] E. S. Kilpatrick, A. G. Rumley, H. Myin, The effect of variations in hematocrit, mean cell volume and red blood count on reagent strip tests for glucose, *Ann Clin Biochem* **30** (1993) 485–487.
- [6] E. F. Treo, C. J. Felice, M. C. Tirado, M. E. Valentinuzzi, and D. O. Cervantes, Hematocrit measurement by dielectric spectroscopy, *IEEE Transactions on Biomedical Engineering* **25** (1) (2005) 124–127.
- [7] Blinded.
- [8] G.-B. Huang, Learning capability and storage capacity of two-hidden-layer feedforward networks, *IEEE Transactions on Neural Networks* **14** (2) (2003) 274–281.
- [9] G.-B. Huang, Q.-Y. Zhu, C.-K. Siew, Extreme learning machine: theory and applications, *Neurocomputing* **70** (2006) 489–501.
- [10] Q.-Y. Zhu, A. K. Qin, P. N. Suganthan, G.-H. Huang, Evolutionary extreme learning machine, *Pattern Recognition* **38** (2005) 1759–1763.
- [11] H. T. Huynh and Y. Won, Small number of hidden units for elm with two-stage linear model, *IEICE Trans. on Information and Systems* **E91-D** (4) (April 2008).
- [12] H. T. Huynh, J. Kim, and Y. Won, An improvement of extreme learning for compact single hidden layer feedforward neural networks, *International Journal of Neural System* **18** (5) (2008) 433–441.
- [13] H. T. Huynh, J. Kim, and Y. Won, Performance comparison of slfn training algorithms for dna microarray classification, *Advances in Experimental Medicine and Biology* **696** (2011) 135–143.
- [14] N.-Y. Liang, G.-H. Huang, P. Saratchandran, and N. Sundararajan, A fast and accurate online sequential learning algorithm for feedforward networks, *IEEE Trans. on Neural Networks* **17** (2006) 1411–1423.

Ngày nhận bài 24 - 2 - 2013

Nhận lại sau sửa ngày 02 - 8 - 2013