

Un método inteligente para estimar el umbral de lactato de atletas recreacionales de manera accesible y no invasiva

Urtats Etxegarai

Departamento de Automática, Control e Ingeniería de Sistemas, Escuela de Ingeniería, Universidad del País Vasco UPV/EHU, Bilbao, España
urtats.etxegarai@ehu.eus

Eva Portillo

Departamento de Automática, Control e Ingeniería de Sistemas, Escuela de Ingeniería, Universidad del País Vasco UPV/EHU, Bilbao, España
eva.portillo@ehu.eus

Jon Irazusta

Departamento de Fisiología, Facultad de Medicina y Enfermería, Universidad del País Vasco UPV/EHU, Bilbao, España
jon.irazusta@ehu.eus

Resumen

El umbral de lactato es considerado una variable fisiológica útil como apoyo a prescripción de entrenamientos y como indicador del rendimiento en deportes de resistencia. Hoy en día no existe un método fiable para evaluarlo sin hacer uso de equipamiento especializado y/o acudir a costosos centros, de manera que su uso está restringido a aquellos atletas que dispongan de estos recursos. Este trabajo propone un método inteligente para estimar el umbral de lactato de manera eficiente, accesible y no invasiva para que una población más amplia pueda tener acceso a ella. Para ello, se propuso un método basado en relativización de factores combinado con redes neuronales recurrentes que en este trabajo ha continuado desarrollándose enfocándolo hacia la mejora de la capacidad de generalización, calibrándolo con una base de datos nueva. Como resultado, se ha alcanzado una capacidad de generalización del 87%. Esto indica que el método aquí presentado es una herramienta válida para estimar el umbral de lactato de manera accesible y no invasiva en corredores recreacionales.

Palabras clave: Umbral de lactato, Aprendizaje automático, Generalización, Redes Neuronales.

1 INTRODUCCIÓN

El umbral de lactato (UL) es la intensidad de ejercicio a la que la concentración de lactato en sangre comienza a crecer significativamente en comparación con los valores en reposo. El umbral de lactato es considerado una variable esencial para

valorar el rendimiento de corredores recreacionales y de élite [18,13] así como para la prescripción de intensidades de ejercicio en deportes de resistencia [2,12]. Hoy en día no existe un método fiable que permita estimarlo de manera no-invasiva y accesible y por lo tanto, la estimación de umbral de lactato a partir de la medición de concentración de lactato en sangre es aún el estándar en cuanto a fiabilidad. Como consecuencia, su uso está aún restringido a unos pocos atletas con recursos suficientes para adquirir equipamiento especializado o acudir a centros especializados. Por lo tanto, el principal objetivo de este trabajo es crear un sistema inteligente capaz de estimar el umbral de lactato de atletas de resistencia de manera accesible y no-invasiva. De entre los diferentes protocolos utilizados para estimar el umbral de lactato a partir de la medición de la concentración de lactato en sangre, hoy en día el método Dmax es el más recomendado [21]. En este método, cada atleta realiza un test de carrera incremental sobre un tapiz rodante donde se van tomando muestras de sangre para caracterizar la curva de lactato. A partir de esta curva, el UL es estimado como el punto de la curva que muestra una mayor distancia con respecto a la intersección entre el primer y último punto de la curva. El sistema inteligente que proponemos tiene este método como el estándar a replicar en cuanto a fiabilidad y haciéndolo de manera accesible y no-invasiva. Más concretamente, este trabajo trata de continuar desarrollando el sistema inteligente propuesto en trabajos previos [9] enfocándonos en incrementar el poder de generalización del modelo, y por medio de una base experimental nueva, determinar sus límites y calibrarlo en consonancia. El resto del artículo está organizado de la siguiente manera: La sección 2 hace una revisión del estado-del-arte presentando los diferentes métodos de estimación de lactato

propuestos hasta ahora, la sección 3 presenta la metodología de entrenamiento y selección de modelo utilizada para evaluar e incrementar la capacidad de generalización; la sección 4 describe la preparación experimental; la sección 5 presenta los resultados y la discusión y finalmente la sección 6 ofrece las conclusiones del trabajo.

2 ANTECEDENTES

Tradicionalmente la estimación del umbral de lactato se ha basado en la toma directa de muestras de sangre. En cambio, se han realizado esfuerzos significativos en la búsqueda de una solución no-invasiva de la estimación del umbral de lactato. Como se muestra en la Fig. 2, hasta ahora se han propuesto diversos enfoques.

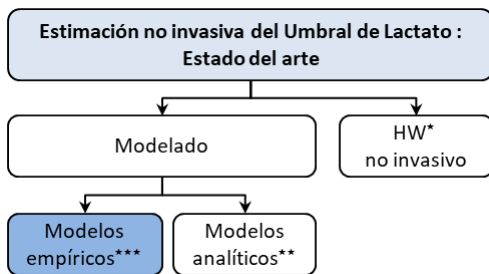


Figura 1: Estimación no-invasiva del umbral de lactato. *[4]; ** [19]; *** [8,9].

El uso de hardware (HW) especializado no-invasivo como el propuesto por Borges y col. [4] está entre este tipo de estrategias. En cambio, estas estrategias requieren de dispositivos caros, de manera que no cumple nuestro requisito de fácil accesibilidad. El metabolismo de lactato es un sistema complejo en el que el resultado es consecuencia de las interacciones entre múltiples variables. Por lo tanto, hoy en día no existe una función analítica que resuelva este problema no-lineal y complejo, incluso parametrizando dichos modelos por medio de múltiples medidas individuales [19]. En este tipo de problema, las estrategias de modelado empírico son probablemente más adecuadas. Las redes neuronales artificiales han sido ampliamente usadas para resolver problemas no-lineales y en algún caso han sido utilizadas para modelar la producción de lactato en atletas. Erdogan y col. [10] propusieron un modelo basado en una perceptrón multicapa para estimar la frecuencia cardíaca (FC) en el inicio de acumulación de lactato en sangre (OBLA), que corresponde con una concentración de lactato en sangre de 4 mmol/l. En cambio, se sabe que el punto OBLA, como corresponde a un valor fijo de concentración de lactato, no considera las diferencias inter-individuales del lactato, especialmente en el caso de atletas de variada capacidad atlética como es el nuestro. Esta es una de las principales razones por

las que el umbral de lactato calculado por el método Dmax es actualmente el más recomendado [21] y el que se usa como referencia en nuestro trabajo. Es más, al modelar a partir de datos empíricos, la precisión estimada en una determinada muestra no es una métrica significativa del error de generalización si no está acompañada por una metodología robusta que busque minimizar el problema de sobre-entrenamiento [5]. Por lo tanto, la validez del modelo propuesto por Erdogan y col. [8] está limitada por su propia metodología, ya que esta se centra exclusivamente en maximizar la precisión del modelo y estimar el error de generalización con sus ejemplos de test, siendo más propenso a crear modelos sobreentrenados. Por lo tanto, de entre los diversos métodos para estimar el umbral de lactato de manera no-invasiva ninguno cumple con nuestros requisitos de fiabilidad y accesibilidad. En trabajos previos [9] propusimos un método inteligente basado en redes neuronales recurrentes (RNR) para estimar el umbral de lactato de atletas recreacionales y este trabajo tiene como objetivo continuar hacia la búsqueda de un método inteligente tan fiable como el basado en tomas de muestras en sangre.

3 ESTRATEGIA DE MODELADO INTELIGENTE

Para crear un sistema inteligente aplicable al rendimiento deportivo que cumpla los objetivos previamente establecidos, es esencial construir un modelo alrededor de dos características enfrentadas. Por una parte, la individualización es clave para el rendimiento deportivo. Por otra, se busca un modelo válido para la población objetivo al completo. Crear una base de datos capaz de caracterizar completamente la población objetivo no es viable desde el punto de vista económico y técnico, de manera que el objetivo de este trabajo es buscar un compromiso entre individualización-generalización que proponga una solución suficiente. Por lo tanto, definir lo que una solución "suficiente" significa para el problema que se tiene entre manos es fundamental. Para un problema de modelado, una solución suficiente es aquella en la que el error del modelo esté dentro de los límites de lo considerado un error máximo aceptable. En el caso de los modelos empíricos, este error es definido por el error fuera-de-muestra o error de generalización. Como el error de generalización no es computable, su correcta estimación es esencial para no subestimar las asunciones del modelo y está estrechamente relacionado con el sesgo-varianza [5]. Por lo tanto, la metodología de modelado aquí propuesta busca la obtención de una solución suficiente en la que: Primero, se define una métrica desde la perspectiva de la aplicación que fije el mínimo rendimiento requerido del modelo para su aplicabilidad y segundo, se crea un modelo con un error de

generalización dentro de los límites de esta métrica. Esta metodología sigue 3 pasos que están representados en la Fig. 2.

3.1. DEFINICION DE LA MÉTRICA

La métrica aquí presentada determina el rendimiento general del modelo combinando un indicador estadístico y uno heurístico. El indicador estadístico valora el rendimiento del modelo calculando la correlación entre el umbral de lactato empírico y el umbral de lactato estimado. Como este enfoque solo analiza el problema desde una perspectiva global y sin considerar el rendimiento sobre cada atleta individual, se propone un indicador heurístico (*i.e.* un enfoque para solucionar problemas que no garantiza ser óptimo, pero sí suficiente) para analizar el modelo desde una perspectiva individual y práctica.

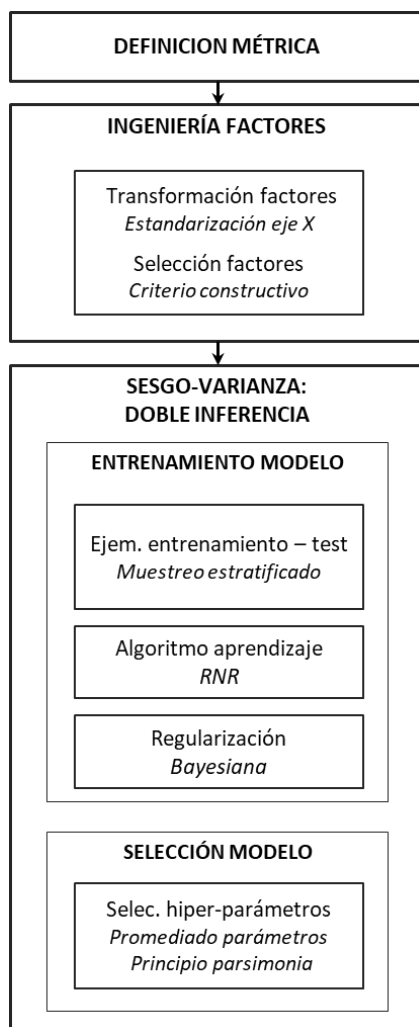


Figura 2: Estrategia de modelado.

En cuanto a la aplicabilidad del modelo en rendimiento deportivo, existe un error máximo por encima del cual el modelo no sería útil. Teniendo como referencia que el error de medición del umbral

de lactato está alrededor del 4-6% [16], hemos enriquecido esta información desde la perspectiva fisiológica de la siguiente manera: Cuanto mayor es el nivel del atleta, mayor es la precisión requerida en la estimación (para individualizar el entrenamiento) y viceversa [6,20]. El error máximo definido de acuerdo con el ritmo de carrera a umbral de lactato está por lo tanto representado en la Tabla 1 y la estimación de error de cada atleta es la diferencia entre el umbral de lactato empírico y el umbral de lactato estimado.

Tabla 1: Definición de error máximo aceptable.

Ritmo a UL (min/km)	Error máximo en UL	
	±(s/km)	±(%)
≤3,5*	3	1,7
[3,5-4]	5	2,4
[4-4,5]	10	4,2
[4,5-5]	15	5,5
≥5	20	6,6

*Atletas fuera del ámbito de este proyecto

El rendimiento del modelo es por lo tanto definido contando el número de estimaciones que están por debajo del error máximo definido en la Tabla 1 y se representa con respecto al % total de atletas en la base de datos (% individualización). Este valor representa el porcentaje de umbrales de lactato correctamente estimados. Ambos indicadores tienen sus fortalezas: El indicador estadístico da comprensión sobre las características globales del modelo mientras el heurístico sobre la aplicabilidad. Además, ambos indicadores permiten comparar el rendimiento de los modelos entre los ejemplos de entrenamiento y test, que es esencial para poder estimar el poder de generalización del modelo. Por lo tanto, la métrica aquí propuesta estima el rendimiento del modelo de acuerdo con el mejor compromiso entre ambos indicadores, presentándose como un método para acortar distancias entre la teoría y la práctica.

3.2. INGENIERÍA DE FACTORES

En gran medida, el rendimiento de un sistema de aprendizaje automático depende de la ingeniería de factores. Como resultado, gran parte de los esfuerzos que actualmente se invierten en el desarrollo de un sistema de aprendizaje automático se desempeñan en el pre-procesado y transformación de datos [11]. En este trabajo se propone utilizar un método de transformación de factores en combinación con un método de selección para representar los datos de una manera que el algoritmo de aprendizaje automático pueda aprender la información más relevante de ella.

3.2.1. Transformación de factores: Relativización de la intensidad del ejercicio

La prueba de esfuerzo que los atletas realizan para el cálculo del umbral de lactato es un test máximo que acaba cuando el atleta no consigue mantener la velocidad de carrera. Como los atletas con un mejor estado de forma son capaces de mantener velocidades más altas, la duración de la prueba depende del estado de forma individual de cada atleta. En nuestro caso, como los atletas recreacionales tienen niveles de forma muy diversos, las pruebas difieren en duración, y como se muestra en la Fig. 3A, también la evolución de sus factores. Debido a las características de la producción de lactato durante la prueba de esfuerzo, su evolución es convexa independientemente de la máxima velocidad alcanzada. En otras palabras, el umbral de lactato no está relacionado con el valor absoluto de la intensidad del ejercicio sino con el punto de ruptura de la curva. Siendo así, en este trabajo se propone la estandarización del eje temporal (*i.e.* el eje de velocidad de carrera) de manera que la dinámica de la curva se desacopla del valor absoluto de la velocidad pico alcanzada.

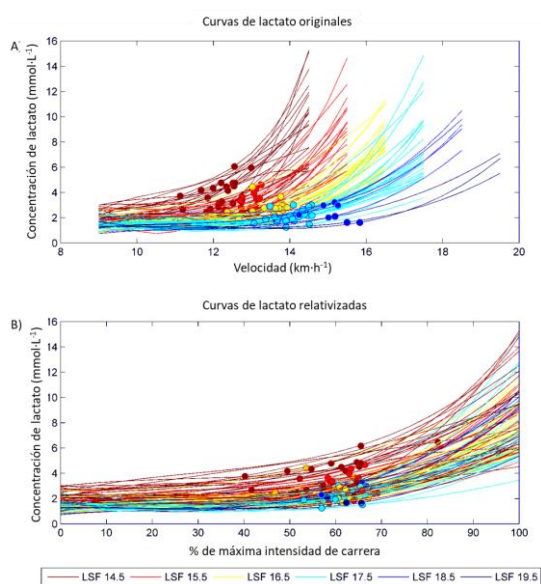


Figura 3: Curvas de Lactato Experimentales
 A) Curvas originales
 B) Curvas relativizadas

Como se muestra en la Fig. 3B, la estandarización permite agrupar los atletas de diferentes estados de forma respecto al % de intensidad máxima alcanzada y tratarlos como un único grupo.

3.2.2. Selección de factores: Estrategia constructiva

De entre los factores fisiológicos que se sabe que están relacionados con la concentración de lactato en sangre, los derivados de la FC, índice de esfuerzo percibido (RPE), edad y el género cumplen los

criterios de ser fácilmente medibles y contener información inter-individual [14]. Como, en igualdad de condiciones, el modelo con menos parámetros, *i.e.* el más parsimonioso, tiende a generalizar mejor [7], minimizar el número de factores de entrada es importante para obtener un modelo con mayor capacidad de generalización. En este caso se propone una estrategia constructiva: El modelo más simple es comparado con un modelo que incorpora el siguiente factor más representativo, y esto se repite hasta que la adición de un factor más no mejora la calidad del modelo anterior. Los factores seleccionados para esta estrategia constructiva son, en orden de prioridad, los siguientes:

1. Evolución de la frecuencia cardíaca al final de cada escalón (FC_{evo})
2. Evolución de la frecuencia cardíaca después de un minuto de recuperación (FC_{Revo})
3. Evolución del índice de esfuerzo percibido (RPE_{evo})

3.3. COMPROMISO SESGO-VARIANZA: DOBLE INFERENCIA

La evaluación no-sesgada y robusta del rendimiento sigue siendo la piedra angular del aprendizaje automático [5]. El error en la evaluación del rendimiento de un modelo puede ser descompuesto en dos componentes, sesgo y varianza. La varianza refleja la variabilidad de la estimación alrededor del valor esperado y esta se debe a la muestra en la que la evaluación se ha llevado a cabo. Minimizar el término de la varianza en ambas inferencias (entrenamiento y selección de modelo) es por lo tanto fundamental para una correcta evaluación del rendimiento [5].

3.3.1. Entrenamiento del modelo

3.3.1.1. Selección de ejemplos de test y entrenamiento

La división de la base de datos en ejemplos de entrenamiento y test se debe hacer de manera que la población objetivo (*i.e.* corredores recreacionales) se vea representada en ambos grupos. En este caso se ha seleccionado una división de 70-30% para los ejemplos de entrenamiento y test respectivamente. Habitualmente, esta separación suele hacerse por muestreo aleatorio, en cambio, este planteamiento solo es válido cuando la base de datos es suficientemente grande para que el muestreo aleatorio sea estadísticamente significativo. El muestreo propuesto en este trabajo es una variación del muestreo aleatorio estratificado que ya ha sido demostrado válido para este problema [9]. En este método, la población se clasifica en grupos mutuamente excluyentes y más homogéneos llamados *strata*. A continuación, se realiza un

muestreo aleatorio de cada *stratum* de manera que se crea una muestra heterogénea con ejemplos de todas las sub-poblaciones. En nuestro caso la variable que se considera más determinante no es estática como es habitual sino la propia dinámica de la curva de lactato. Por lo tanto, se ha utilizado una técnica de clusterización de series temporales para hacer la estratificación de acuerdo con este factor. En este caso, se ha utilizado una técnica de clusterización jerárquica para hacer la división de *stratum* ya que permite no preseleccionar el número de clústeres y hace una comparación punto a punto de las curvas, siendo esto conveniente en casos como el nuestro en el que las series temporales están relativizadas para que tengan la misma longitud. Una vez que se define el *strata*, el 30% de los ejemplos de cada *stratum* son aleatoriamente seleccionados e incluidos como ejemplos de test y el restante como ejemplos de entrenamiento.

3.3.1.2 Algoritmo de entrenamiento

Se ha elegido una arquitectura de red neuronal de capa re currente (LRNN) con propósito de realizar los entrenamientos. El LRNN es una red neuronal basada en la red Elman que tiene la flexibilidad de configurar el número de capas ocultas (HU) y la función de transferencia de cada capa (Delay) [1]. Para ajustar los parámetros del modelo se ha elegido la función de minimización Levenberg-Marquardt ya que tiene velocidades de convergencia mayores y ratios de error menores que otros algoritmos de minimización habitualmente utilizados [10]. Como el mínimo encontrado durante el entrenamiento también depende de los valores iniciales de los pesos de la red neuronal, cada una de las redes es entrenada diez veces con diferente inicialización de pesos. En este caso se ha aplicado el algoritmo propuesto por Nguyen y Widrow [17] ya que reduce el tiempo de entrenamiento en comparación con otros métodos de inicialización como el capa-a-capa o la inicialización aleatoria. El modelo ha sido entrenado utilizando Matlab R2013b y los toolbox Neural Network y Statistics and Machine Learning (MathWorks, Natick, Massachusetts, USA).

3.3.1.3 Regularización

Los métodos de generalización más utilizados son la validación cruzada y la regularización Bayesiana. El primero divide la base de datos en ejemplos de entrenamiento, validación y test para estimar el poder de generalización del modelo. En cambio, la regularización Bayesiana no necesita de fase de validación, de manera que la base de datos solo es dividida en dos partes, entrenamiento y test. Esto significa que, siguiendo este planteamiento, se pueden utilizar más ejemplos para entrenamiento,

permitiendo aprovechar mejor nuestra base de datos además de poder conseguir una capacidad de generalización mayor que con la validación cruzada [15].

3.3.2. Selección de modelo

La selección del modelo es una parte integral de la inferencia que se realiza en el proceso de modelado y un incorrecto protocolo de selección del modelo puede crear una subestimación del sesgo en el rendimiento del mismo [5]. Por lo tanto, en este trabajo se proponen dos métodos diferentes de selección de modelo.

3.3.2.1. Promediado de hiper-parámetros

Es conocido que el promediado de hiper-parámetros es una manera efectiva de evitar el sobre-entrenamiento en el proceso de selección de modelo [5]. Se fundamenta en promediar los hiper-parámetros de los múltiples modelos entrenados de manera que se seleccionen los hiper-parámetros para los que se haya obtenido un mínimo local de manera consistente.

3.3.2.2. Principio de parsimonia

El principio de parsimonia es también conocido como un método para maximizar el poder de generalización de un modelo [7]. Esta metodología elige el modelo más simple de entre los que mejor rendimiento han demostrado, en este caso aquel que tiene menos hiper-parámetros (*i.e.* menos HU y Delays).

4 DATOS EXPERIMENTALES

Los modelos han sido entrenados con la misma base de datos presentada en [9] y que consta de 105 atletas. Para continuar desarrollando el modelo, definir sus límites y calibrarlo adecuadamente, se recogió una muestra experimental completamente nueva con 50 corredores recreacionales con el objetivo de utilizarlo en la evaluación de la capacidad de generalización de los modelos. El proceso de selección de atletas estaba enfocado a buscar perfiles de atletas de la población objetivo que estuviesen insuficientemente representados en la primera muestra experimental recogida para [9], de manera que los límites de generalización del modelo pudiesen ser mejor definidos. Por lo tanto, se ha incluido una amplia variedad de atletas en esta nueva base de datos. De los 50 atletas, 25 son completamente nuevos y otros 25 ya habían participado en la primera fase experimental, pero se encontraban ahora en un estado de forma distinto. Factores como género, edad, disciplina deportiva y nivel han sido tenidos en cuenta. Además, se han

realizado entrevistas personales para asegurarse de que los objetivos experimentales estaban siendo satisfechos. Los protocolos de adquisición y pre-procesado de datos han sido los mismos que en [9], donde los corredores completaron una prueba máxima incremental de carrera sobre un tapiz rodante con una inclinación de 1%. Al igual que en [9], La prueba comenzó con una velocidad de 9 km/h y la velocidad fue incrementándose en 1,5 km/h cada 4 minutos hasta 13,5 km/h y después en 1 km/h hasta que el/la atleta llegase al agotamiento. Entre escalones se dio 1 minuto de recuperación para tomar las muestras de sangre en el lóbulo y medir la concentración de lactato. A su vez, se adquirieron los valores de RPE y FC al finalizar cada escalón y después del periodo de recuperación de 1 minuto.

5 RESULTADOS Y DISCUSIÓN

5.1. ENTRENAMIENTO DEL MODELO

Se han creado múltiples modelos utilizando diferentes configuraciones de hiper-parámetros. Este proceso de entrenamiento se ha repetido para diferentes combinaciones de factores de entrada siguiendo el criterio constructivo previamente establecido. Como se muestra en la Tabla 3, el rendimiento de los modelos es muy similar usando diferentes combinaciones.

Tabla 2: Rendimiento vs factores de entrada.

Factores de entrada	Indicad. Heurist. (%)	Indicad. Statist. (R)
-	90,48	0,89
FCevo	91,43	0,89
FCevo, FCRevo	91,43	0,89
FCevo, FCRevo, RPEevo	91,43	0,89

El modelo sin entradas muestra un buen rendimiento, lo que puede significar que la mayor parte de la información de la evolución del lactato es extraída de su evolución previa. La introducción de FCevo incrementa el rendimiento debido a la información extra que este factor provee.

Tabla 3: Ranking de modelos.

Rnk	Hiper-Param.			Indicad. Heurist. (%)	Indicad. Statist. (R)
	HU	Del	Comp.		
1	1	8	8	91,43	0,89
2	1	7	7	91,43	0,89
3	1	10	10	90,63	0,89
4	4	11	44	90,63	0,89
5	1	10	10	90,63	0,89
6	2	6	12	89,52	0,89
7	4	11	44	89,52	0,89

8	2	8	16	89,52	0,89
9	2	7	14	89,52	0,89
10	3	10	30	89,52	0,89

En cambio, la introducción de factores adicionales como FCRevo o RPEevo no incrementa el rendimiento, lo que puede significar que la información que estas contienen sea menos relevante y/o redundante. Por lo tanto, de entre las cuatro combinaciones de factores de entrada, el modelo con la entrada FCevo es considerada la mejor por su compromiso entre baja complejidad y buen rendimiento. Los 10 mejores modelos entrenados de esta manera están ordenados de acuerdo con la métrica previamente definida en la Tabla 3.

5.2. SELECCIÓN DEL MODELO

5.2.1. Promediado de hiper-parámetros

El promediado de hiper-parámetros se hace a partir de los modelos entrenados con tal de encontrar la configuración (HU y Delay) que consistentemente encuentre un mínimo local (Fig. 4). Existen diferentes zonas en las que consistentemente se obtienen mejores resultados en este análisis. Desde el punto de vista de la generalización, las zonas menos complejas son de un mayor interés y como está resaltado en la Fig. 4, la mejor zona aparece consistentemente en torno a 2 HU y 6 Delay. Por lo tanto, el modelo final seleccionado mediante este método es el que ocupa el 6º lugar en la Tabla 3.

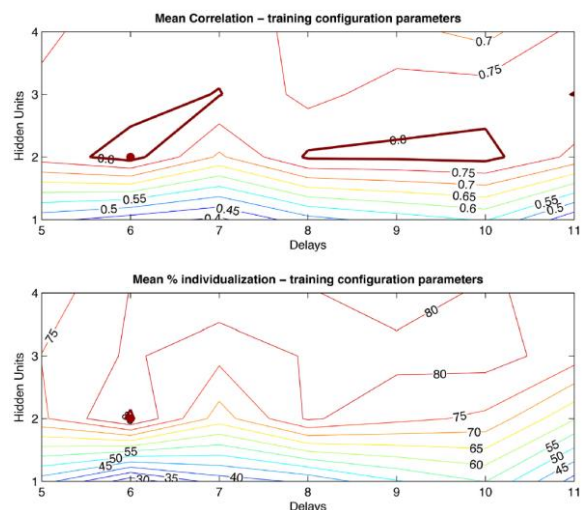


Figura 4: Promedio de rendimiento del modelo VS Hiper-parámetros

5.2.2. Principio de parsimonia

El modelo final seleccionado por el principio de parsimonia es el de menor complejidad, que en este caso tiene 1 HU y 7 Delays y el que se encuentra en la segunda posición en la Tabla 3.

5.3. ANÁLISIS DE APLICABILIDAD

Para evaluar la aplicabilidad de ambos modelos aquí presentados, se ha revalorado su rendimiento con la nueva base de datos de 50 atletas. Estos resultados se recogen en la Tabla 4 y la Fig. 5 representa dos curvas de lactato estimadas con respecto a las originales.

Tabla 4: Generalización vs método de selección.

Método de selección	Indicad. Heurist. (%)	Indicad. Statist. (R)
Promedio hiper-parámetros	64	0.79
Principio de parsimonia	87	0.88

Por un lado, los resultados muestran que el modelo seleccionado por promedio de hiper-parámetros tiene un gran sesgo en la estimación de error del modelo ya que no rinde bien en la nueva base de datos. Por otro lado, el modelo seleccionado mediante el principio de parsimonia ofrece un rendimiento similar al de la base de datos experimental de [9]. Los resultados muestran que el modelo seleccionado usando el principio de parsimonia es muy bueno y que el incremento de la complejidad del modelo seleccionado por el promediado de hiper-parámetros ha podido incrementar su varianza y consecuentemente el sesgo en la estimación del error [5]. Por lo tanto, el modelo con 1 HU y 7 Delay muestra una alta capacidad de generalización, lo que indica que su fiabilidad y robustez son altas.




Figura 5: Curvas lactato estimadas

6 CONCLUSIONES

En este trabajo hemos propuesto un sistema inteligente que estima el umbral de lactato de corredores recreacionales de manera no-invasiva y accesible. Para hacer frente al problema de sesgo en la estimación del rendimiento de un modelo se han utilizado dos métodos de selección, obteniendo una correcta estimación de umbral de lactato en el 91% de los casos en una primera base de datos experimental. Para poder estimar los límites de la

capacidad de generalización del modelo, se realizó una segunda recogida experimental en la que los atletas participantes fueron seleccionados según los perfiles que podían estar incompletos en la primera fase experimental. Sobre esta nueva base de datos, el modelo seleccionado por el principio de parsimonia mostró una gran capacidad de generalización prácticamente igualando la correcta estimación de umbral de lactato en la primera fase experimental (91% vs 87%). Por lo tanto, el modelo aquí presentado muestra una gran fiabilidad y robustez y se presenta como un serio candidato para la estimación de umbral de lactato de manera no-invasiva y accesible en corredores recreacionales.

Agradecimientos

Este trabajo ha sido financiado por Grupo Campus S.L. [proyectos LACTATUS 2016 y LACTATUS]; el Departamento de Desarrollo Económico y Competitividad del Gobierno Vasco [Gaitek 2015]; la Universidad del País Vasco UPV/EHU [proyectos PPG17/56 y PPG/17/40]; y el Departamento de Educación del Gobierno Vasco [beca PRE 2015 1 0129].

English summary

An intelligent method to estimate the lactate threshold accessibly and non-invasively in recreational runners

Abstract

Lactate threshold is considered an essential physiological variable useful for endurance sports as an aid for training prescription and performance evaluation. However, nowadays there is no reliable way to assess it without specialized equipment or without turning to expensive centres, meaning that it is restricted to few people with access to these resources. Thus, this work proposes a cost-efficient, non-invasive and easily accessible intelligent method to estimate the lactate threshold and so making it accessible to a wider population. A new strategy based on feature standardization combined with Recurrent Neural Network was proposed to model the lactate threshold. In this work, this method is further developed to increase its generalization power and calibrated against a new database. The results show that this system successfully estimates the lactate threshold in 87% of the cases, meaning that our model is a valid accessible tool for lactate threshold assessment.

Keywords: Lactate threshold, Machine Learning, Generalization, Neural Networks.

Referencias

[1] Arriandiaga, A; Portillo, E; Sánchez, J.A; Cabanes, I; Pombo, I; (2015) A new approach for dynamic modelling of energy consumption in the grinding process using recurrent neural networks, *Neural Comput. Appl.*

[2] Acevedo, E.O; Goldfarb, A.H; (1989) Increased training intensity effects on plasma lactate, ventilatory threshold, and endurance, *Med. Sci. Sports Exerc.* 21 563–568.

[3] Borg, G; (1982) Psychophysical bases of perceived exertion, *Med. Sci. Sports Exerc.* 14 377–381.

[4] Borges, N.R; Driller, M.W; (2016) Wearable lactate threshold predicting device is valid and reliable in runners, *J. Strength Condition. Res.* 30 2212–2218.

[5] Cawley, G.C; Talbot, N.L.C; (2010) On Overfitting in Model Selection and Subsequent Selection Bias in Performance Evaluation. *Journal of Machine Learning Research*, 11 2079–2107

[6] Davison, R.C.R; van Someren, K.A; Jones, A.M; (2009) Physiological monitoring of the Olympic athlete, *J. Sports Sci.* 27 1433–1442.

[7] Dreyfus, G; *Neural Networks. Methodology and Applications*, Springer, Berlin, Heidelberg, 2005.

[8] Erdogan, A; Cetin, C; Goksu, H; Guner, R; Baydar, M.L; (2009) Non-invasive detection of the anaerobic threshold by a neural network model of the heart rate-work rate relationship, *Proc. Inst. Mech. Eng. P: J. Sports Eng. Technol.* 223 109–115.

[9] Etxegarai, U; Portillo, E; Irazusta, J; Arriandiaga, A; Cabanes, I; (2018) Estimation of lactate threshold with machine learning techniques in recreational runners. *Applied Soft Computing* 63 181–196

[10] Hagan, M.T; Menhaj, M.B; (1994) Training feedforward networks with the Marquart algorithm, *IEEE Trans. Neural Netw.* 5 989–993.

[11] Heaton, J; (2016) An empirical analysis of feature engineering for predictive modeling, *SoutheastCon* 1–6.

[12] Hofmann, P; Tschakert, G; (2017) Intensity- and duration-based options to regulate endurance training, *Front. Physiol.* 8 337.

[13] Lacour, J.R; Padilla-Magunacelaya, S; Barthélémy, J.C; Dormois, D; (1990) The energetics of middle-distance running, *Eur. J. Appl. Physiol.* 60 38–43.

[14] López Chicharro, J; Aznar Laín, S; Fernández Vaquero, A; López Mojares, L.M; Lucía Mulas, A; Pérez Ruiz, M; (2004) *Transición aeróbica-anaeróbica: concepto, metodología de determinación y aplicaciones*, 1st ed., Master Line & Prodigio.

[15] MacKay, D.J.C; (1992) A practical Bayesian framework for backpropagation networks, *Neural Comput.* 4 448–472.

[16] Meyer, K; (1996) Ventilatory and lactate threshold determinations in healthy normals and cardiac patients: methodological problems, *Eur. J. Appl. Physiol.* 72 387–393.

[17] Nguyen, D; Widrow, B; (1990) Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights, *IJCNN Int. JointConf. Neural Netw.* 13 C21.

[18] Pallarés, J.G; Morán-Navarro, R; Ortega, J.F; Fernández-Elías, V.E; Mora-Rodríguez, R; (2016) Validity and reliability of ventilatory and blood lactate thresholds in well-trained cyclists, *PLOS ONE* 11 1–16.

[19] Proshin, A.P; Solodyannikov, Y.V; (2013) Mathematical modeling of lactate metabolism with applications to sports, *Autom. Remote Control* 74 (6) 1004–1019.

[20] Reilly, T; Morris, T; Whyte, G; (2009) The specificity of training prescription and physiological assessment: a review, *J. Sports Sci.* 27 575–589.

[21] Santos-Concejero, J; Tucker, R; Granados, C; Irazusta, J; Bidaurrezaga-Letona, I; Zabala-Lili, J; Gil, S.M; (2014) Influence of regression model and initial intensity of an incremental test on the relationship between the lactate threshold estimated by the maximal-deviation method and running performance, *J. Sports Sci.* 32 853–859.



© 2018 by the authors.
Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 3.0 license (<https://creativecommons.org/licenses/by-nc/3.0>).