

Aprendizaje máquina con transferencia de información

PEDRO J. GARCÍA-LAENCINA¹, ANTONIO SÁNCHEZ-GARCÍA²,
ANDRÉS BUENO-CRESPO³, JUAN MORALES-SÁNCHEZ¹,
MARÍA CONSUELO BASTIDA-JUMILLA¹, JORGE LARREY-RUIZ¹,
JOSÉ-LUIS SANCHO-GÓMEZ¹

1. Departamento de Tecnologías de la Información y las Comunicaciones.
Universidad Politécnica de Cartagena.
2. Área Técnica de Estudios Avanzados y Tratamiento Digital de la Señal.
Sociedad Anónima de Electrónica Submarina (SAES).
3. Departamento de Informática de Sistemas.
Universidad Católica San Antonio.

pedroj.garcia@upct.es; a.sanchez@electronica-submarina.com;
abueno@pdi.ucam.edu; juan.morales@upct.es;
jorge.larrey@upct.es; mc.bastida@upct.es;
jl.sancho@upct.es

Resumen

Este artículo presenta los conceptos básicos y fundamentales relativos a máquinas de aprendizaje con transferencia de información entre tareas relacionadas. Las capacidades y ventajas de esta metodología se demuestran en un ejemplo real de predicción de series temporales de carácter financiero.

Proyecto/Grupo de investigación: Grupo de Teoría y Tratamiento de Señal. Entidad financiadora: Ministerio de Educación y Ciencia. Proyecto TEC2006-13338/TCM.

Líneas de investigación: *Procesado Digital de Imágenes; Reconocimiento Estadístico de Patrones.*

1 Introducción

En un problema de reconocimiento de patrones [1], una máquina de aprendizaje $f(\cdot)$ realiza un mapeado del vector de características asociados a cada patrón (\mathbf{x}) a una variable objetivo o *target* (t). En otras palabras, f modela t a partir de \mathbf{x} , $f(\mathbf{x}) \approx t$. De esta forma, se entiende por *aprendizaje inductivo* al proceso de inferencia que construye un modelo, $f(\cdot)$, de una variable objetivo, t , a partir

de inferencia que construye un modelo, $f(\cdot)$, de una variable objetivo, t , a partir de un conjunto de patrones de entrenamiento asociados a t .

Las máquinas de aprendizaje existentes hasta hace más una década se centraban en resolver un problema de reconocimiento de patrones, ya sea de regresión o clasificación, sin ningún tipo de información adicional/auxiliar que pudiera resultar beneficiosa para el aprendizaje. El uso conjunto de conceptos relacionados y relevantes con la tarea objetivo puede mejorar el aprendizaje final de la misma. Este artículo presenta y analiza la transferencia de información en máquinas de aprendizaje, incluyendo el concepto de sesgo inductivo, el uso de ‘hints’ y el aprendizaje multi-tarea. Por último, se presentan los resultados experimentales obtenidos en un problema real.

2 Sesgo inductivo

El entrenamiento libre, es decir, sin restricciones, de una máquina de aprendizaje para modelar una determinada tarea puede conducir a una ineficiente capacidad de resolución y generalización de la misma [1]. Una solución adecuada es emplear el concepto de *sesgo inductivo* [2]. Se entiende por sesgo inductivo todo aquello que induce a una máquina a preferir unas soluciones sobre otras. Un sesgo inductivo puede ser beneficioso para el aprendizaje por diversas situaciones, como aumentar la capacidad de generalización de la máquina o disminuir el tiempo necesario de entrenamiento. Un sesgo inductivo positivo reduce el espacio de soluciones dirigiendo el aprendizaje a las soluciones correctas; mientras que un sesgo negativo provocará que el espacio de soluciones sea mayor y por tanto no beneficiará el proceso de aprendizaje.

La mayoría de técnicas de aprendizaje con sesgo inductivo se fundamentan en el uso de información auxiliar o de un conocimiento previo acerca del modelo y/o de la tarea a resolver, que pueda facilitar la optimización de parámetros en el espacio de soluciones. Atendiendo a [3], se define con el término *hint* a toda información auxiliar acerca del problema a resolver que se pueda utilizar para guiar el aprendizaje, es decir, cualquier tipo de información acerca del modelo (f) o de la tarea (t) que pueda incorporar un sesgo inductivo durante la etapa de entrenamiento. Un ‘hint’ siempre proporciona una nueva información en el proceso de aprendizaje, y conlleva incorporar un sesgo inductivo a dicho proceso.

3 Transferencia de información entre múltiples tareas

Se ha demostrado que el uso de ‘hints’ conlleva la *transferencia de información* auxiliar al aprendizaje de la tarea objetivo, donde dicha información guía y dirige la búsqueda de los parámetros del modelo en el espacio de posibles soluciones. Una manera muy recomendada y extendida para obtener información auxiliar en un determinado problema es emplear *tareas relacionadas* con dicho

problema. El aprendizaje a partir de información procedente de múltiples tareas conlleva una transferencia de conocimiento entre los distintos procesos de aprendizaje implicados en cada una de las tareas. Si las distintas tareas a aprender proporcionan nueva información entre sí que pueda dirigir y guiar el aprendizaje de las mismas, se producirá una transferencia positiva de información entre ellas, y con ello mejorará la capacidad de generalización y/o la velocidad de convergencia de la máquina entrenada. Generalmente, siguiendo esta metodología, se pretende transferir conocimiento (de manera positiva) de una o más tareas, conocidas como *tareas secundarias*, a una tarea objetivo, conocida como *tarea principal*. El conjunto total de tareas, formado por la principal y las secundarias, se conoce como *dominio*. El único objetivo de las tareas secundarias es guiar y dirigir el modelado de la tarea principal durante el aprendizaje simultáneo de todas las tareas.

Dada una tarea principal a modelar, un enfoque estándar de *aprendizaje mono-tarea* (Single Task Learning, STL) construye una única máquina para aprender dicha tarea. Dentro de las distintas técnicas de aprendizaje con transferencia de información, destaca el *aprendizaje multi-tarea* (Multi-Task Learning, MTL) [4]. MTL es el término más extendido para referirse a la transferencia de información producida por el aprendizaje simultáneo de múltiples tareas.

3.1 Relación entre tareas

MTL conlleva una transferencia positiva de información si las tareas aprendidas están relacionadas [4]. Siguiendo este argumento, *¿qué se entiende por relación entre tareas?* La respuesta a esta pregunta no es sencilla. Considérese una máquina MTL (denotada por f) entrenada para resolver en paralelo una tarea principal t_1 y una tarea secundaria t_2 . La siguiente expresión define el concepto de relación entre tareas:

$$\text{Relación}(t_1, t_2, f) = 1 \iff \text{Aprendizaje}(t_1 \cup t_2 | f) > \text{Aprendizaje}(t_1 | f). \quad (1)$$

Según (1), existe una relación entre t_1 y t_2 si f es capaz de aprender mejor t_1 al entrenar simultáneamente dicha tarea junto con t_2 que en el caso de modelar específicamente t_1 mediante la misma máquina. De esta forma, existe una conexión directa entre el concepto de sesgo inductivo y relación entre tareas, ya que t_1 y t_2 están relacionadas si el aprendizaje simultáneo de ambas mediante una misma máquina produce un sesgo inductivo positivo en el modelado de t_1 . Por otro lado, es importante distinguir entre relación y correlación estadística, ya que si las tareas a aprender están totalmente correladas no existirá una información adicional que guíe el aprendizaje de la tarea principal. Según esta aproximación, el grado de relación entre t_1 y t_2 es proporcional al grado de mejora en el aprendizaje de t_1 al modelar simultáneamente ambas tareas.

4 Resultados experimentales

Se ha empleado un problema real de carácter financiero cuyo objetivo es modelar el *tipo de interés hipotecario a 30 años en EEUU*. En concreto, se dispone de un conjunto de datos asociado compuesto por 1049 vectores de entrada, correspondientes a las medidas semanales de 14 variables económicas desde 01/04/1980 hasta 02/04/2000. Los datos proceden de la Reserva Federal del Banco de St. Louis, y están accesibles en el repositorio de la Universidad de Bilkent ¹.

Se consideran dos enfoques: STL y MTL. Según un enfoque STL, se modela directamente la variable objetivo a partir de un conjunto de entrenamiento mediante una máquina de aprendizaje. En cambio, según un enfoque MTL, es necesario añadir una o más variables (tareas secundarias) que serán modeladas conjuntamente con la variable objetivo (tarea principal) mediante una misma máquina. En concreto, se considera como tarea secundaria *el tipo de interés de un depósito a plazo de un mes en EEUU*. La Figura 1 (a) muestra la serie temporal asociada a la tarea principal (interés hipotecario), mientras que la Figura 1 (b) muestra la serie temporal correspondiente a la tarea secundaria (interés de un crédito con plazo mensual). En dichas figuras, es evidente comprobar la relación existente entre estas dos variables, ya que ambas dependen del precio del dinero establecido por la Reserva Federal estadounidense.

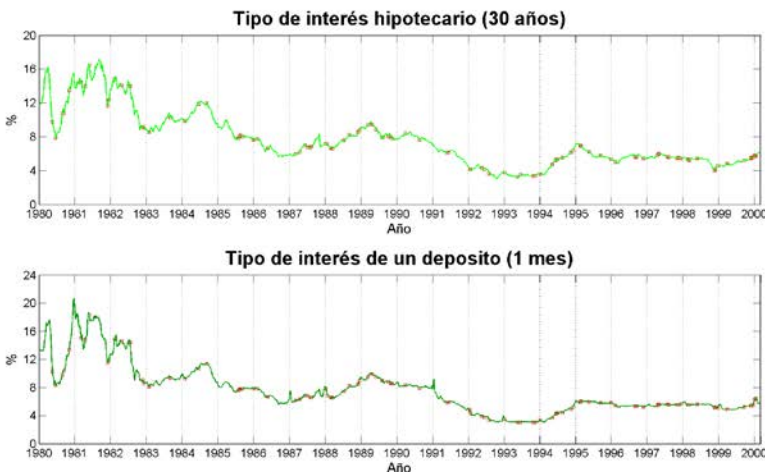


Figura 1: Evolución de la tasa de interés hipotecario a un plazo de 30 años (a) y la tasa de interés de un depósito bancario a un plazo mensual (b) en EEUU desde 01/04/1980 hasta 02/04/2000.

¹<http://funapp.cs.bilkent.edu.tr/DataSets/>

El conjunto de datos es dividido en dos partes: entrenamiento (100 patrones escogidos aleatoriamente) y test (los restantes 949 casos). En la Figura 1, se muestra con cuadrados los patrones de entrenamiento. El modelado de este problema ha sido realizado mediante una red neuronal con 5 neuronas ocultas, con funciones de activación de tipo tangente hiperbólica, y salidas lineales (una salida para el esquema STL y dos salidas para el esquema MTL). Los valores iniciales de los parámetros (pesos) que definen las arquitecturas STL y MTL son idénticos, con el objetivo de poder comparar correctamente los resultados obtenidos por ambas máquinas. Para los modelos STL y MTL de la tarea principal, la Figura 2(a) muestra la evolución del coste de entrenamiento, mientras que la Figura 2(b) muestra la evolución del coste del conjunto de test (capacidad de generalización).

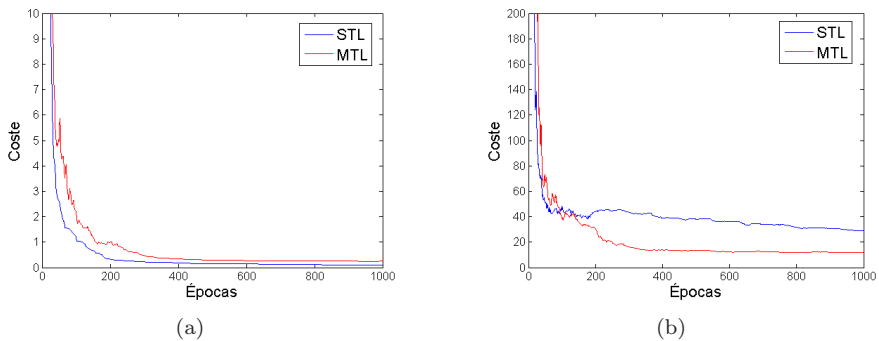


Figura 2: Evolución del coste de la tarea principal en la fase de entrenamiento (a) y test (b) empleando arquitecturas STL y MTL.

Como es directo comprobar en dichas figuras, la máquina MTL presenta una mejor capacidad de generalización, obteniendo un aprendizaje más rápido según los resultados obtenidos en el conjunto de entrenamiento. Esto es debido a que el aprendizaje simultáneo con la tarea secundaria evita que la máquina sobreentrene la tarea principal, como ocurre en el modelado STL (ver Figura 2(a)), y permite aumentar la capacidad de generalización para dicha tarea al utilizar la información contenida en la secundaria.

Por último la Figura 3 muestra la aproximación realizada por los modelos STL y MTL para el tipo de interés hipotecario (tarea principal), siendo **29,22** y **12,25**, respectivamente, el error cuadrático medio obtenido por las máquinas STL y MTL. Este error ha sido medido utilizando el conjunto total de datos que componen el problema. En conclusión, la arquitectura MTL ha obtenido una mejora de un **58,8%** sobre la solución obtenida mediante el esquema STL.

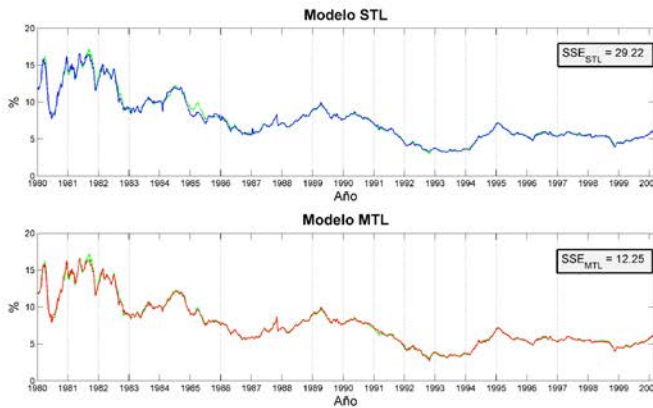


Figura 3: Modelado de la serie temporal ‘Tipo de interés hipotecario a 30 años en EEUU’ mediante máquinas STL (a) y MTL (b).

5 Conclusiones

La incorporación de información auxiliar al proceso de aprendizaje de un determinado problema (tarea principal) mediante una máquina de aprendizaje puede conducir a una mejora en la resolución del mismo. Dicha información auxiliar puede encontrarse en el propio problema o en otros problemas relacionados (tareas secundarias) con la tarea principal. Para mostrar las ventajas de esta metodología se ha empleado un problema de regresión con datos de carácter económico.

Referencias

- [1] C. M. Bishop. *Neural Networks for Pattern Recognition*. New York, USA: Oxford University Press. 1995.
- [2] J. Baxter. A model of inductive bias learning. *Journal of Artificial Intelligence Research*, 12:149-198, 2000.
- [3] Y. S. Abu-Mostafa. Hints. *Neural Computation*, 7(4):639-671, 1995.
- [4] R. Caruana. Multitask learning. *Machine Learning*, 28(1):41-75. 1997.