



UNIVERSIDADE DA CORUÑA



# Aprendizaje en Grandes Volúmenes de Datos Mediante un Nuevo Método Distribuido y No Iterativo para Redes de Neuronas de Una Capa


Óscar Fontenla Romero  
Marcelo Gómez Casal  
Bertha Guijarro Berdiñas  
Beatriz Pérez Sánchez

# Aplicaciones Prácticas del Aprendizaje Automático

- ▶ Detección de ataques informáticos y/o spam
- ▶ Identificación de fraudes
- ▶ Sistemas de recomendación
- ▶ Clasificación de clientes
- ▶ Diagnóstico médico o de sistemas
- ▶ Análisis de estructuras complejas
- ▶ Estudio del estado de la bolsa



**amazon**




# Problema: Tamaño de los Conjuntos de Datos

- ▶ Incremento del tamaño en dos direcciones:
  1. Crecimiento constante de las bases de datos
    - Aumento continuo del número de muestras
    - Ejemplo: Bolsa, Industria, Sistemas de Recomendación
  2. Estudio de campos con datos complejos
    - Manejo de muestras con muchas características
    - Ejemplo: Análisis de Estructuras de ADN
- ▶ Conjuntos más grandes = Proceso de aprendizaje más lento
  - Minimizar el impacto del tamaño sobre los tiempos de entrenamiento
  - Importancia de la escalabilidad en los métodos de Aprendizaje Automático



# Problema: La Escalabilidad de los Métodos


- ▶ Uso de algoritmos iterativos
- ▶ Se centran en la eficacia, escalabilidad relegada a segundo plano



- ▶ No se explota la posibilidad de distribución



- ▶ Ajuste exhaustivo parámetros para maximizar eficacia




# Propuesta de un Nuevo Método: El LANN-DSVD

- ▶ Red de neuronas sin capa oculta: Tantas entradas como atributos
- ▶ Aprendizaje no iterativo gracias a:
  - Nuevo punto de medida de error (antes de función de activación)
  - Factorización de matrices SVD (Singular Value Decomposition)

$$\mathbf{W} \approx \mathbf{U}(\mathbf{S}\mathbf{S}^T)^\dagger \mathbf{U}^T \mathbf{X}\mathbf{F}\mathbf{F}^d$$


SVD

Medida del Error




# Propuesta de un Nuevo Método: EL LANN-DSVD

- ▶ Aprendizaje distribuido e incremental



- ▶ Buena escalabilidad
  - No iterativo
  - No precisa ajuste de parámetros por parte del usuario
  - Equilibrio entre eficacia y eficiencia



METHOD

Un simple dibujo de un rectángulo con líneas negras, que parece ser un espacio reservado para un diagrama o una descripción de un método.

# Validación: SVM vs. LANN-DSVD

- ▶ Se plantean cinco escenarios de clasificación

| Conjunto    | Nº de Muestras | Nº de Atributos |
|-------------|----------------|-----------------|
| Breast      | 683            | 10              |
| MiniBooNE   | 130.064        | 50              |
| Susy        | 5.000.000      | 18              |
| HearthStone | 2.000.000      | 44              |
| Higgs       | 11.000.000     | 28              |

- Comparación de eficacia y eficiencia
  - ¿Qué método resuelve mejor el problema?
  - ¿Qué método termina antes el entrenamiento?

# Validación: SVM vs. LANN-DSVD

Eficacia (% AUC)



Eficiencia (s)

| Conjunto    | SVM                          | LANN-DSVD    | SVM                          | LANN-DSVD    |
|-------------|------------------------------|--------------|------------------------------|--------------|
| Breast      | 96,66 ± 2,37                 | 99,5 ± 0,50  | 0,034 ± 0,04                 | 0,18 ± 0,01  |
| MiniBooNE   | 89,54 ± 0,34                 | 95,50 ± 0,20 | 383,35 ± 35,52               | 0,37 ± 0,01  |
| Susy        | Más de 1 semana sin terminar | 83,60 ± 0,00 | Más de 1 semana sin terminar | 3,66 ± 0,21  |
| HearthStone | Más de 1 semana sin terminar | 78,60 ± 0,70 | Más de 1 semana sin terminar | 4,51 ± 0,11  |
| Higgs       | Más de 1 semana sin terminar | 68,30 ± 0,00 | Más de 1 semana sin terminar | 12,05 ± 0,42 |

| Conjunto    | Método de Referencia | Eficacia de Referencia |
|-------------|----------------------|------------------------|
| Susy        | Deep Neural Network  | 87,9 ± 0,1             |
| HearthStone | (No Revelado)        | 80,18 ± ¿?             |
| Higgs       | Deep Neural Network  | 88,50 ± 0,2            |


# Conclusiones

- ▶ En general la precisión es comparable a la de los métodos más eficaces
- ▶ Para conjuntos grandes, el LANN-DSVD es más rápido
  - Idóneo para conjuntos con muchas muestras y/o atributos
- ▶ Importancia del equilibrio entre eficacia y eficiencia
  - Las SVM no terminan a tiempo en el caso de los conjuntos más grandes
- ▶ Aprendizaje absolutamente automático
  - LANN-DSVD no precisa de un ajuste de parámetros por parte del usuario
- ▶ Permite aprendizaje compartido preservando la privacidad
  - Entre varias entidades, transmitiendo solo el modelo (vector de pesos)



# Aplicaciones del LANN-DSVD

- ▶ Posible entrenar muchos modelos sin necesidad de un supercomputador
  - Cualquier máquina de hoy en día soporta 4 u 8 hilos de ejecución
- ▶ Escenarios que precisen de aprendizaje en tiempo real
  - No entrenar el modelo con todas las muestras al querer añadir nuevas
  - Ejemplo: Sistemas de Recomendación
- ▶ Aprendizaje compartido entre diferentes entidades
  - Distribuir el entrenamiento para aprender con datos de diferentes fuentes
  - Al contar con más datos, todas las entidades implicadas se benefician
  - Se preserva la privacidad de los datos originales
  - Ejemplo: Bolsa, Medicina





UNIVERSIDADE DA CORUÑA



# Aprendizaje en Grandes Volúmenes de Datos Mediante un Nuevo Método Distribuido y No Iterativo para Redes de Neuronas de Una Capa

Óscar Fontenla Romero  
Marcelo Gómez Casal  
Bertha Guijarro Berdiñas  
Beatriz Pérez Sánchez