



Machine Learning en Fusión Nuclear



Gonzalo Farías Castro

Escuela de Ingeniería Eléctrica Pontificia Universidad Católica de Valparaíso

Madrid, 20 de Febrero de 2018

Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación
- 5. Resultados recientes y desafíos

Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación
- 5. Resultados recientes y desafíos

Requerimientos de energía

- Para 2100 se espera requerir hasta el cuádruple de energía*
- El carbón es ampliamente utilizado, pero tiene un enorme impacto ambiental.
- Los combustibles fósiles son recursos no renovables.
- La fisión nuclear produce basura radioactiva.



* International climate policy architectures: Overview of the EMF 22 International Scenarios, Clarke et al, Energy Economics, 2009

La fusión nuclear como alternativa

- La fusión se presenta de forma natural en la energía que producen las estrellas.
- La fusión nuclear ocurre como resultado de reacciones termonucleares a altas temperaturas (150MM °C).
- En estas condiciones, la materia se convierte en plasma: Gas caliente compuesto de partículas cargadas eléctricamente.
- En un dispositivo de fusión el plasma se mantiene confinado magnéticamente, mediante bobinas, en lo que se conoce como la cámara de vacío toroidal.
- Se estima que, en teoría un reactor podría llegar a generar **1 GW/H** con sólo **30 gramos** de combustible.

La fusión nuclear como alternativa



La fusión nuclear como alternativa

Ventajas

- Energía prácticamente inagotable.
- El "Combustible" es abundante: el deuterio se obtiene del agua de mar y el litio se encuentra distribuido en todo el mundo.
- No se producen residuos radiactivos, sólo Helio.
- En caso de emergencia, el proceso vuelve a "reposo" sin ningún tipo de actuación.

Limitaciones

- Tecnológicamente difícil de controlar.
- No se conoce bien la física del proceso.
- Los costes son elevados (ITER, € 15 Mil Millones).

Dispositivos y datos en fusión: TJ-II



Dispositivos y datos en fusión: DIII-D



Dispositivos y datos en fusión: JET



Dispositivos y datos en fusión: ITER



Dispositivos y datos en fusión: Descarga



https://youtu.be/YwdWyAcZr90

Introducción

Motivación: Elevada instrumentación



Motivación: Diagnósticos

- Densidad y temperatura (electrónica e iónica)
- Contenido de impurezas
- Pérdidas por radiación
- Energía contenida en el plasma
- Rotación poloidal y toroidal del plasma
- Eficiencia de calentamiento
- Campos eléctricos
- Fluctuaciones e inestabilidades
- Estructura magnética y corrientes en el plasma
- Etc....

Motivación: Bases de datos masivas

- Un pulso de unos segundos de duración puede generar grandes cantidades de información.
- En el TJ-II tiene más de 1000 canales de medida.
- Un pulso puede durar en JET una decena de segundos.
- Alrededor de **10GBytes por pulso** pueden ser almacenados en JET, **100 TBytes por año**.
- ITER podría generar **1TB por pulso**, **1PBytes por año**.

¡¡Se estima que sólo el 10% de los datos son analizados!!

Motivación

Se requieren SISTEMAS AUTOMÁTICOS de procesamiento de la información.

¿Cuándo aplicar Machine Learning?

✓ Existe un patrón

 ✓ No se puede describir el patrón matemáticamente

✓ Tenemos datos acerca del patrón

¿Para qué es útil machine learning?



*Predictive Analytics with Microsoft Azure Machine Learning: Build and Deploy Actionable Solutions in Minutes Problema: Clasificar el pez que pasa por una cinta transportadora utilizando un sensor óptico. Se asume que únicamente hay dos tipos de peces: Salmón y Róbalo.



Proceso de decisión (Análisis del Problema):

¿Qué clase de información puede distinguir una especie de otra?

Longitud Brillantez Anchura Número y forma de las aletas Posición de la boca, etc ...

¿Qué problemas pueden existir durante la sensorización?

Distintas condiciones de luz Posición del pez en la cinta Ruido de la cámara, etc ...

¿Qué pasos se deben de seguir en el proceso de decisión?

Capturar la imagen Aislar el pez Tomar medidas Clasificarlo (toma de decisión)

- Un pescador nos comenta que por lo general un Róbalo es más largo que un Salmón.
- Por tanto, para clasificar los peces podemos utilizar la característica de la longitud.

¿Cómo podemos seleccionar el umbral de la longitud?

A partir de "peces de entrenamiento"

 Por tanto, en principio seleccionamos un umbral *l** y entrenamos, tal que:

Si longitud < *I** entonces Salmón, en caso contrario Róbalo.

Histogramas de la característica longitud para dos clases de peces



Error de entrenamiento = 90 / 316 = 28%

- Aunque de media el Róbalo es más largo que el Salmón existen muchos casos en los que la clasificación es errónea.
- No existe un umbral para una discriminación sin ambigüedad de las dos categorías.
- Por tanto, utilizar únicamente la característica de la longitud para clasificar estos peces no es muy preciso.
- Se escoge la brillantez como otra posible característica para realizar la clasificación.
 - Se selecciona un umbral w^* y entrenamos, tal que:

Si brillantez < w* entonces Salmón, en caso contrario Róbalo.

Histogramas de la característica brillantez para dos clases de peces





Error de entrenamiento = 16 / 316 = 5%

Se consigue una tasa de aciertos mayor, pero sigue sin existir un umbral para una discriminación sin ambigüedad de las dos categorías.

Consideraciones sobre los costes de los diferentes errores

- Hasta ahora hemos asumido que las consecuencias de nuestras acciones tienen igual coste, es decir, decidir que el pescado es un Róbalo cuando en realidad es un Salmón es tan indeseable como lo contrario.
- La planta de envasado sabe que los clientes fácilmente aceptan algunas veces recibir Salmón en las latas etiquetadas como "Róbalo"; pero protestan si ocurre lo contrario.

Para mantener la cartera de clientes se debe de mover el umbral de la brillantez hacia valores menores, de esta forma se reduce el número de Róbalos que son clasificados como Salmones.



La tarea principal de la Teoría de la decisión es tomar una decisión que minimice los costes

- Consideremos dos características en lugar de una para tomar la decisión:
 - La brillantez (x₁)
 - La longitud (x₂)
- Cada imagen se representa ahora por un punto (vector características) en un espacio de características de dos dimensiones.



Diagrama de dispersión de las características de brillantez y anchura para los peces de entrenamiento con una función/regla de decisión lineal



Error de entrenamiento = 8 / 316 = 2,5%

- El error es menor que si se utilizara una única característica.
- Sin embargo, todavía se producen algunos errores.

¿Se mejorará el resultado si se añaden nuevas características?

- Algunas variables pueden ser redundantes.
- Cuidado con los costes de incorporar nuevas características.
- Cuidado con el ruido en las medidas.

¿Se puede obtener una regla de decisión mejor que la anterior?

Diagrama de dispersión de las características de brillantez y anchura para los peces de entrenamiento con una función/regla de decisión compleja



- Modelos complejos para las clases de pescado conducen a fronteras de decisión complicadas.
- Mientras esta decisión conduce a una clasificación perfecta de la muestra de aprendizaje, dará un pobre rendimiento para futuros patrones.
- El punto nuevo marcado como ? evidentemente debería ser clasificado como Salmón, mientras que la frontera complicada conduce a que sea clasificado como Róbalo.

No es fácil de generalizar la regla de decisión.

CONCLUSIÓN: La regla de decisión debe de representar un compromiso óptimo entre el rendimiento sobre las muestras de aprendizaje y la simplicidad del clasificador. Diagrama de dispersión de las características de brillantez y anchura para los peces de entrenamiento con una función/regla de decisión cuadrática



Introducción

Diagrama de procesos de un sistema de RP



Sistema de Reconocimiento de Patrones



Sistema de Reconocimiento de Patrones

Extracción y selección de características



Sistema de Reconocimiento de Patrones

Extracción y selección de características

Extracción: Obtener información de los datos.

- Análisis espectral, espacial y temporal.
- Reducción de dimensionalidad (características).
- Técnicas: Transformadas Fourier, Wavelet.

Selección: Determinar atributos diferenciadores.

- Mapeo espacio entrada espacio características.
- Algoritmos:
 - Análisis de componentes principales -PCA (filtro)
 - Discriminante de Fischer (filtro)
 - Clasificadores (envoltorio-wrapper)
Introducción

Sistema de Reconocimiento de Patrones

Extracción y selección de características

Transformada wavelet (WT)



Clasificación supervisada y no supervisada



Clasificación supervisada y no supervisada

Clasificación supervisada

- Obtener conjuntos de entrenamiento y prueba
- Seleccionar método de aprendizaje automático: SVM
- Experimentación y obtención de estadísticas
- Primar generalidad sobre tasa de acierto
- Validar resultados con expertos

Clasificación no supervisada (más difícil que el anterior)

- Definir si se conoce el número de grupos o no
- Seleccionar algoritmos de agrupamientos (no sólo uno)
- Experimentación y obtención de estadísticas
- Validar resultados con expertos

Clasificación supervisada y no supervisada Máquinas de vectores soporte (SVM): caso lineal



margen = $|d_{+}| + |d_{-}|$

Objetivo: Hiperplano con mayor margen!

$$y_{i}(\mathbf{w}.\mathbf{x}_{i}+b) \geq 1, \quad \forall i$$

$$y_{i}d_{i} \geq \frac{1}{\|\mathbf{w}\|}, \quad \forall i$$

$$\alpha_{i}^{*} > 0 \implies y_{i}(\mathbf{w}^{*}.\mathbf{x}_{i}+b^{*}) = 1$$

$$d_{+}-d_{-} = \frac{2}{\|\mathbf{w}\|}$$

$$d_{+}-d_{-} = \frac{2}{\|\mathbf{w}\|}$$

$$\lim_{\mathbf{w},b} \quad \frac{1}{2}\mathbf{w}.\mathbf{w}$$
sujeto a $y_{i}(\mathbf{w}.\mathbf{x}_{i}+b) \geq 1, i = 1, \dots, l$

Clasificación supervisada y no supervisada Máquinas de vectores soporte (SVM): caso no lineal



Sistema de Reconocimiento de Patrones Clasificación supervisada y no supervisada Máquinas de vectores soporte (SVM): multiclasificador

Un hiperplanos por cada clase:



Sistema de Reconocimiento de Patrones Codificación y búsqueda



Sistema de Reconocimiento de Patrones Codificación y búsqueda

Codificación

- Seleccionar método de codificación: SPR
- Aplicar codificación a toda la base de datos.

Búsqueda

- Definir métrica de similitud
- Aplicar codificación a patrón de entrada
- Definir método de búsqueda (ej. cadenas texto)
- Determinación de patrones similares
- Validar resultados con expertos

Codificación y búsqueda

Reconocimiento de patrones estructural (SPR)

2222222 2222222



Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación
- 5. Resultados recientes y desafíos

Clasificación supervisada de series temporales

Motivación: Reducción de espacio de búsqueda





Table 2.1: Some temporal signal classes acquired in TJ-II.

Signal class	Description
RX306	Soft X-ray
ACTON275	Spectroscopic signal (CV)
HALFAC3	H_{α}
DENSIDAD2	Line averaged electron density
BOL5	Bolometer signal
ECE7	Electron cyclotron emission

Clasificación supervisada de series temporales Aproximación: WT+SVM



Clasificación supervisada de series temporales Resultados y otras aplicaciones

- G. Farias, R. Dormido, M. Santos, N. Duro (2005) Image classifer for the TJ-II Thomson Scattering diagnostic: Evaluation with a feed forward neural network, *Lecture Notes in Computer Science*, ISSN 0302-9743, Volume 3562, Part 2, Pages 604-612, Springer-Verlag.
 - Extracción de características: Transformada Wavelet
 - Método de clasificación: Red neuronal feed-foward
 - Tasa de acierto promedio: 90%
- L. Makili, J. Vega, S. Dormido-Canto, I. Pastor, A. Pereira, G. Farias, A. Portas, D. Pérez-Risco, M.C. Rodríguez-Fernández, P. Busch (2010) Upgrade of the automatic analysis system in the TJ-II Thomson Scattering diagnostic: New image recognition classifier and fault condition detection, Fusion Engineering and Design, ISSN 0920-3796, Volume 85, Issues 34, Pages 415-418.
 - Extracción de características: Transformada Wavelet
 - Método de clasificación: Máquina de vectores soporte
 - Tasa de acierto promedio: 98%

Clasificación supervisada de series temporales Resultados y otras aplicaciones

- N. Duro, R. Dormido, J. Vega, S. Dormido-Canto, G. Farias, J. Sánchez, H. Vargas, A. Murari and JET-EFDA Contributors (2009) Automated recognition system for ELM classification in JET, Fusion Engineering and Design, ISSN 0920-3796, Volume 84, Issues 2-6, Pages 712-715.
 - Extracción de características: Información estructural del ELM (period, drop, CM)
 - Método de clasificación: Máquina de vectores soporte, K-medias y jerárquico
 - Tasa de acierto promedio: 95%
- S. Dormido-Canto, G. Farias, J. Vega, R. Dormido, J. Sánchez, N. Duro, H. Vargas, A. Murari, and JET-EFDA Contributors (2008) Classifer based on support vector machine for JET plasma configurations, *Review of Scientific Instruments*, ISSN 0034-6748, Volume 79, Pages 10F326-1/10F326-3.
 - Extracción de características: Información estructural de la superficie del plasma
 - Método de clasificación: Máquina de vectores soporte
 - Tasa de acierto promedio: 97%

Clasificación no supervisada de series temporales Resultados y otras aplicaciones

- J.A. Martín, M. Santos, G. Farias, N. Duro, J. Sánchez, R. Dormido, S. Dormido-Canto, J. Vega, H. Vargas, (2009) Dynamic clustering and modeling approaches for fusion plasma signals, *IEEE Transactions on Instrumentation and Measurement*, ISSN 0018-9456, Volume 58, Number 9, Pages 2969-2978.
 - Extracción de características: Información estructural o señal entera.
 - Método de clasificación no supervisada: Agrupamiento dinámico propio.
- N. Duro, J. Vega, R. Dormido, G. Farias, S. Dormido-Canto, J. Sánchez, M. Santos, G. Pajares (2006) Automated clustering procedure for TJ-II experimental signals, Fusion Engineering and Design, ISSN 0920-3796, Volume 81, Pages 1987- 1991, Ed. Elsevier.
 - **Extracción de características**: Transformada wavelet y transformada discreta de fourier
 - Método de clasificación no supervisada: K-medias, jerárquico, grand tour, red neuronal ART.

Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación
- 5. Resultados recientes y desafíos

Motivación: Patrones similares podría implicar física similar



Aproximación: Reconocimiento estructural de patrones



Aproximación: Reconocimiento estructural de patrones



Fig. 4. Primitive sequences in an input pattern with the different methods.

Aproximación: Reconocimiento estructural de patrones



Motivación: Determinar localización de transición L-H



Búsqueda de inform



Aproximación: Usar SVMs para determinar transición



Feature Selection +-100ms



+-50ms	+-100ms
fs04da (Dα signal)	fs04da (Dα signal)
density (density)	density (density)
echpwrc (ECH power)	poh (ohmic power)
ip (plasma current)	<pre>prad_tot (radiated power)</pre>
<pre>prad_tot (radiated power)</pre>	totalpower
totalpower	

Predicción final: Seleccionar de dos aproximaciones



- (1) Vega, J., Murari, A., Vagliasindi, G., Ratta, G. & Contributors, J. (2009), `Automated estimation of L/H transition times at JET by combining bayesian statistics and support vector machines', Nuclear Fusion 49(8), 085023.
- (2) Gonzalez, S., Vega, J., Murari, A., Pereira, A., Dormido-Canto, S. & Ramrez, J. (2012), `H/L transition time estimation in JET using conformal predictors', Fusion Engineering and Design 87(12), 2084{2086.

Resultados

INTERVAL	M1	M2	M3	M1 & M2
<-105	26	8	44	9
-100	0	0	0	0
-90	0	0	1	0
-80	0	2	0	0
-70	0	6	2	2
-60	2	4	2	1
-50	1	1	1	1
-40	0	3	0	1
-30	0	3	0	0
-20	1	21	2	1
-10	2	32	4	3
0	290	157	3	257
10	6	34	4	9
20	0	3	0	0
30	1	3	2	1
40	2	2	5	2
50	0	3	2	2
60	0	4	2	1
70	1	2	3	1
80	0	1	3	0
90	0	0	10	0
100	0	2	8	0
>105	3	4	139	4



Interval

Búsqueda de patrones en formas de onda y eventos Resultados y otras aplicaciones

- S. Dormido-Canto, G. Farias, R. Dormido, J. Sánchez, N. Duro, H. Vargas, J. Vega, G. Ratta, A. Pereira, A. Portas (2008) Structural pattern recognition methods based on string comparison for fusion database, *Fusion Engineering and Design*, ISSN 0920-3796, Volume 83, Issue 2-3, Pages 421-424. Ed. Elsevier.
- G. Rattá, J. Vega, A. Pereira, A. Portas, E. De la Luna, S. Dormido-Canto, G. Farias, R. Dormido, J. Sánchez, N. Duro, H. Vargas, M. Santos, G. Pajares, A. Murari, and JET EFDA Contributors (2008) First applications of structural pattern recognition methods to the investigation of specific physical phenomena at JET, *Fusion Engineering and Design*, ISSN 0920-3796, Volume 83, Issue 2-3, Pages 467-470. Ed. Elsevier.
- J. Vega, A. Pereira, A. Portas, S. Dormido-Canto, G. Farias, R. Dormido, J. Sánchez, N. Duro, M. Santos, E. Sánchez, G. Pajares (2008) Data mining technique for fast retrieval of similar waveform in Fusion massive databases, *Fusion Engineering and Design*, ISSN 0920-3796, Volume 83, Issue 1, Pages 132-139. Ed. Elsevier.
- G. Farias, J. Vega, S. González, A. Pereira, X. Lee, D. Schissel, P. Gohil (2012) Automatic determination of L/H transition times in DIII-D through a collaborative distributed environment, Fusion Engineering and Design, ISSN 0920-3796, Volume 87, Issue 12, Pages 2081-2083.

Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación
- 5. Resultados recientes y desafíos

Perfiles de temperatura y densidad del plasma





Pattern	Description
BKGND	CCD Camera background
CUTOFF	Plasma reaching the cut-off density during ECH heating
ECRH	Plasma during ECH heating
NBI	Plasma during NBI heating
STRAY	A collapsed discharge

Table 1 Patterns or classes of the TJ-II Thomson Scattering Diagnostic.

Ruido por luz parásita



Diagnóstico Scattering Thomson Motivación: Reducir ruido por luz parásita



Motivación: Reducir ruido por luz parásita

Soluciones posibles

- Aplicar filtro hardware: Normalmente costosos
- Aplicar filtro clásico (paso bajo) y avanzados (wavelet): Actúan sobre el ruido pero también sobre la información relevante
- Aplicar algoritmos selectivos de regiones en imágenes.

Aproximación: Segmentación de imágenes



Diagnóstico Scattering Thomson Aproximación: Segmentación de imágenes



Aproximación: Segmentación de imágenes

Imagen original







Resultados y otras mejoras





Nuevo algoritmo iterativo de reducción de ruido

Imágenes binarias para diferentes umbrales

DEMO MATLAB

Resultados y otras mejoras

	0	2	4	6	8	10
NBI	0,3%	0,3%	1,2%	45,8%	96,1%	99,4%
ECRH	0,4%	2,3%	9,3%	56,1%	97,1%	99,5%
CUTOFF	0,0%	2,3%	9,5%	23,8%	92,8%	100,0%
STRAY	1,9%	5,8%	8,2%	20,0%	89,2%	99,0%
Averaae	0.6%	2.7%	7.0%	36,4%	93,8%	99,5%

Porcentaje de imágenes por clase sin ruido en la enésima iteración.

- G. Farias, S. Dormido-Canto, J. Vega, M. Santos, I. Pastor, S. Fingerhuth, J. Ascencio (2013) Iterative stray light reduction on TJ-II Thomson Scattering images, 9th IAEA Technical Meeting on "Control, Data Acquisition, and Remote Participation for Fusion Research", May 06-10, 2013, Hefei, China.
- G. Farias, S. Dormido-Canto, J. Vega, I. Pastor, M. Santos (2013) Application and validation of image processing algorithms to reduce the stray light on the TJ-II Thomson Scattering diagnostic, *Fusion Science and Technology*, ISSN 1536-1055, Volume 63, Number 1, Pages 20-25.
- S. Dormido-Canto, G. Farias, J. Vega, I. Pastor (2012) Image processing methods for noise reduction in the TJ-II Thomson Scattering diagnostic, *Fusion Engineering and Design*, ISSN 0920-3796, Volume 87, Issue 12, Pages 2170-2173.
Contenidos

1. Introducción

- Requerimientos de energía
- La Fusión nuclear como alternativa
- Dispositivos y datos en fusión
- Motivación
- Reconocimiento de patrones

2. Clasificación supervisada y no supervisada

- **Ejemplo**: Clasificación supervisada de diagnósticos de series temporales
- Resultados y otras aplicaciones
 - Clasificación supervisada de configuración de plasma
 - Clasificación no supervisada de diagnósticos y ELMs

3. Búsqueda de información

- **Ejemplos**: Búsqueda de patrones formas de onda y búsqueda de eventos
- Resultados y otras aplicaciones
 - Búsqueda de patrones y formas de onda completa
 - Búsqueda de eventos en descarga

4. Reducción selectiva de ruido

- Ejemplo: Luz parásita en diagnóstico Scattering Thomson
- Resultados y otras mejoras
 - Reducción de ruido y validación

5. Resultados recientes y desafíos

10th IAEA Technical Meeting on Control, Data Acquisition and Remote Participation for Fusion Research



Automatic feature extraction in large fusion databases by using deep learning approach

Gonzalo Farias¹, Sebastián Dormido-Canto², Jesús Vega³, Giuseppe Rattá³

¹Pontificia Universidad Católica de Valparaíso (PUCV), Valparaíso, Chile. ²Universidad Nacional de Educación a Distancia (UNED), Madrid, Spain ³Asociación EURATOM/CIEMAT para Fusión, Madrid, Spain.

IAEA2015, Ahmedabad, April 20-24, 2015

Autoencoders

BKG
COF
ECH
NBI
STR

Image: Strate stra

Fig. 1. The upper plots show the five classes of the TJ-II Thomson Scattering images. Lower plots show the corresponding preprocessed versions of the five classes.

Autoencoders



Fig. 2. TJ-II waveforms. The x-axis represents the time in milliseconds and y-axis is the amplitude of each signal, for our purposes the units are irrelevant.



Fig. 3. An autoencoder with 625 units in the input and output layers, and with 32 units in the hidden layer.



Fig. 4. Input images that activate each one of the 4 units of the autoencoder trained with the TS images.

Autoencoders



Fig. 5. Using the feature extraction with two autoencoders (i.e. a deep network) and a support vector machines to classify the TJ-II databases.

	 1024	_ 8	93,08	12,53	-	
	1024	16	93,79	11,80		
	1004	17	02,20	11 00		
Autoencouers	1024	32	94,49	11,85		
Autoanadara	1024	64	94,56	14,53		
	1021		01.70	14,50		
	1047	140	77.05	13.04		

onzalo Farias, Sebastián Dormido-Canto, Jesús Vega, Giuseppe Rattá, Héctor Vargas, Gabriel Hérmosilla, Luis Alfaro, Agustín Valencia, Automatic feature extraction in large fúsion databases by using deep learning approach, In Fusion Engineering and Design Volume 112, 2016 Bages 979-983 USSN 0920-3796

Table 3. TS image classifier results with one autoencode Engineering and Design, Volume 112, 2016, Pages 979-983, ISSN 0920-3796,

				Table 4	TS image of	laccifier rec	ulte with two out	oen
Input units	Hidden units	Successful rate (%)	Support vectors rate (%)		Hidden	Hidden	Second Second	S
625	-	97,64	47,98	Input	units	units	Successiui	v
625	256	98,57	15,05	units	layer 1	layer 2	rate (%)	ra
625	128	98,42	11,02	625	256	64	97,96	
625	64	97,53	8,65	625	256	32	98,49	
625	32	97,41	6,96	625	256	16	98,60	
625	16	97,71	7,38	625	256	8	97,34	1
625	8	91,56	13,01	625	256	4	85,57	2
625	4	78.21	32.27					

Table	5.	TJ-II	waveform	classifier	results	with	one
autoen	code	r.					

				Input	Hidden	Successful	Support vectors
				units	units	rate (%)	rate (%)
				1024	-	94,68	55,08
				1024	256	94,52	26,85
Innut	Hidden	Hidden	Successful	Support4	128	94,65	15,82
unite	units	units	rate (%)	vectpg24	64	94,56	14,53
unnts	layer 1	layer 2	Tate (70)	rate 1624	32	94,49	11,85
625	256	64	97,96	7,31024	16	93,79	11,80
625	256	32	98,49	6,9024	8	93,08	12,53
625	256	16	98,60	7,80 24	4	91,37	15.09
625	256	8	97,34	11,9024	2	83,37	24,92
625	256	4	85,57	26,11		,	,

Input Hidden Successful Support vectors

units G.uffiariasates%) Dormido(Coanto, J. Vega, G. Rattá, H. Vargas, G. Hermosilla, L. Alfaro, A. Valencia (2016) 625 Automatic⁷ feature ⁴⁷ fraction in large fusion databases by using deep learning approach, Fusion 625 Engineering 4 and Designo ISSN 0920-3796, Volume 112, Issue 11, Pages 979-983.

625	64	97,53	8,65
625	32	97,41	6,96
625	16	97,71	7,38
625	8	91,56	13,01

29th edition of the Symposium on Fusion Technology (SOFT 2016)



Image classification by using a reduced set of features in the TJ-II Thomson Scattering diagnostic

Gonzalo Farias¹, Sebastián Dormido-Canto², Jesús Vega³, Ismael Martinez¹, Ernesto Fábregas²

> ¹Pontificia Universidad Católica de Valparaíso (PUCV), Valparaíso, Chile. ²Universidad Nacional de Educación a Distancia (UNED), Madrid, Spain ³Asociación EURATOM/CIEMAT para Fusión, Madrid, Spain.

> > SOFT2016, Prague, September 5-9, 2016

Rule-based



Input: $S = \{(x_i, y_i), \forall i = 1 ... m\}$ *#S*: Training set example $#D_1$: Initial weight distribution *#m*: Size of the training set $\#y_i \in \{-1, +1\}$ $D_1(i) = \frac{1}{m}, \forall i = 1 \dots m$ #T iterations are performed for $t \coloneqq 1$ to T do # Get a new weak rule $h_t: X \to \{-1, +1\}$ $h_t = GetWeakRule(X, D_t)$ $\epsilon_t = \sum_{i:h_t(x_i) \neq y_i} D_t(i)$ $\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right)$ #Update D_t distribution $D_{t+1}(i) = \frac{D_t(i)\exp(-\alpha_t y_i h_t(x_i))}{Z_t}, \ \forall i = 1 \dots m$ $#Z_t$: Normalization such that D_{t+1} is a distribution: $Z_t = \sum_{i=1}^m D_t(i) \exp\left(-\alpha_t y_i h_t(x_i)\right)$ end for **Output** rule combination: $f(x) = sign(\sum_{t=1}^{T} \alpha_t h_t(x))$ Listing 1. Adaboost algorithm

Rule-based models







Rule-based models



Figure 2: Five type of TJ-II Thomson Scattering images. Red blocks correspond to selected features by the Adaboost algorithm.

Table 1: Accuracy classification of the five TJ-II TS Images.

	BKG	COF	ECH	NBI	STR
AdaboostM1	100%	95,83%	96,88%	98,96%	95,83%

SENSITIVITY ANALYSIS

Each Adaboost classifier uses 100 rules or hypothesis to classify the TJ-II TS images. It is interesting to perform a sensitivity analysis in order to observe the robustness of the method.



Figure 3: Sensitivity analysis for rules (hypothesis) and features.

Note that NBI classifier requires few rules or features to reach a high success rate. The following model of a NBI classifier requires only 3 rules and the success rate is over 98%.

 $ClassNBI(I_{test}) = sign\left(\sum_{1}^{3} \alpha_t \cdot h_t(I_{test})\right) = sign(0,26 \cdot (I_{test}(404) > 1101) + 0,26 \cdot (I_{test}(409) > 1094) + 0,26 \cdot (I_{test}(367) > 1087))$





Machine Learning en Fusión Nuclear



Gonzalo Farías Castro

Escuela de Ingeniería Eléctrica Pontificia Universidad Católica de Valparaíso

Madrid, 20 de Febrero de 2018

Colaboradores

