



Máster de Tecnologías de Telecomunicación

Trabajo Fin de Máster

Técnicas de Reconocimiento Automático de Patrones Aplicadas a Imágenes Hiperespectrales Médicas

Samuel Ortega Sarmiento

Dr. Gustavo Iván Marrero Callicó

D. Rafael Camacho Galán

Septiembre 2016

Resumen

Las imágenes hiperespectrales son una tecnología emergente en el campo de la medicina. Esto es debido a que se ha probado que la interacción electromagnética entre la luz y los tejidos es capaz de proporcionar información útil para el diagnóstico de enfermedades. Las muestras empleadas en este estudio se corresponden con muestras histológicas de tejido cerebral diagnosticadas como sanas o tumorales por un patólogo. Con el objetivo de conseguir una discriminación automática entre tejido sano y tumoral, estas muestras han sido procesadas usando tres tipos de clasificadores supervisados: **Support Vector Machines (SVM)**, **Artificial Neural Networks (ANN)** y **Random Forests (RF)**.

Muestras Biológicas

- Las muestras se componen de portaobjetos que contienen **tejido cerebral humano**.
- Estas muestras se han diagnosticado como **gliomas de alto grado**
- En las muestras proporcionadas, las regiones resaltadas en rojo se corresponden con tejido **tumoral** y las azules con tejido **sano**.
- Se han empleado **19 hiperescubos** capturados a partir de **4 pacientes** diferentes.



Metodología

- Se han definido **tres escenarios** donde se probarán las capacidades de los algoritmos de clasificación:
 - CS1:** Cada paciente es procesado individualmente.
 - CS2:** Todos los datos disponibles son procesados en conjunto.
 - CS3:** Los datos de un paciente son clasificados usando un modelo creado con los datos del resto de pacientes.
- Se ha empleado un *framework* estándar de clasificación supervisada:
 - Preprocesado:** Trata de minimizar los efectos del sistema de medida sobre las imágenes capturadas.
 - Clasificación Supervisada:** Se emplean tres algoritmos de clasificación diferentes: **SVM**, **ANN** y **RF**.
 - Evaluación de los modelos:** Dependiendo del escenario, los modelos son validados usando **10-fold cross validation** o **hold-out**.



Resultados de clasificación

CS1

Classifier	Patient number	Overall Accuracy	Sensitivity	Specificity
SVM Linear	1	99.04%	99.29%	98.76%
	2	98.48%	98.75%	98.20%
	3	99.67%	99.87%	99.52%
SVM RBF	1	97.34%	97.56%	97.10%
	2	97.18%	97.47%	96.89%
	3	98.78%	99.81%	98.06%
ANN	1	99.17%	99.13%	99.20%
	2	99.95%	99.96%	99.94%
	3	99.82%	99.90%	99.76%
RF	1	98.77%	98.67%	98.88%
	2	99.66%	99.73%	99.58%
	3	99.36%	99.77%	99.07%

CS2

Classifier	Overall Accuracy	Sensitivity	Specificity
SVM Linear	94.46%	95.15%	93.66%
SVM RBF	92.78%	94.55%	90.83%
ANN	98.20%	98.72%	97.61%
RF	97.91%	98.06%	97.75%

CS3

Classifier	Patient number	Overall Accuracy	Sensitivity	Specificity
SVM Linear	1	81.85%	86.94%	77.57%
	2	64.64%	75.96%	59.66%
	3	68.92%	59.33%	83.87%
	4	10.74%	10.74%	-
SVM RBF	1	73.86%	79.19%	69.65%
	2	61.19%	68.46%	57.51%
	3	58.44%	50.58%	83.52%
	4	94.50%	94.50%	-
ANN	1	48.15%	50.03%	46.19%
	2	47.26%	47.80%	46.99%
	3	33.02%	15.23%	42.72%
	4	99.20%	99.20%	-
RF	1	47.75%	49.60%	46.13%
	2	38.50%	39.53%	37.51%
	3	41.29%	39.27%	47.62%
	4	88.04%	88.40%	-

Conclusiones

- Se han obtenido buenos resultados en la discriminación entre tejido sano y tumoral para los escenarios CS1 y CS2.
- En CS3 los resultados no son tan buenos, esto puede ser debido al reducido número de pacientes disponibles.
- Ha sido posible discriminar entre tejido sano y tumoral únicamente atendiendo a la firma espectral.
- En un futuro este tipo de herramientas podrán asistir a los patólogos en el diagnóstico.

