

Tabla de Contenido

1. Introducción	1
1.1. Motivación	1
1.2. Objetivos	3
1.3. Estructura del trabajo	4
2. Marco Teórico	5
2.1. Proteínas y Enzimas	5
2.1.1. Estructura primaria, secundaria y terciaria	5
2.1.2. Dominios	7
2.1.3. Números EC	7
2.1.4. UnitProtKB	8
2.2. Búsqueda por Similitud: BLAST	9
2.3. Acercamiento a Aprendizaje de Máquinas	10
2.3.1. Extracción de características	12
2.3.2. Escalar datos	13
2.3.3. Selección de características	13
2.3.4. Clasificadores	14
2.3.5. Selección de modelos	17
2.4. Predicción de funcionalidad de proteínas basados en Machine Learning	19
2.4.1. En la literatura	19
2.4.2. Critical assessment of functional annotation	20
3. Herramientas utilizadas	22
3.1. Lenguaje de programación	22
3.2. CD-HIT	23
3.3. Diamond	23
3.4. InterPro	23
4. Metodología e Implementación	25
4.1. Primeras pruebas	25
4.1.1. Uso de ProFET	26
4.1.2. Uso de InterPro	27
4.2. BLAST	28
4.2.1. Comportamiento en enzimas	28
4.2.2. Comportamiento sobre proteínas	31
4.3. Propuesta	32

5. Resultados	37
5.1. Modelo sin ajuste de parámetros	37
5.2. Modelo con ajuste de parámetros	38
5.2.1. Caso F-Test	38
5.2.2. Caso Información mutua (MI)	39
5.2.3. Porcentajes de mejora sobre clases	40
5.2.4. Número de vecinos utilizados en KNN	40
5.2.5. Número de características seleccionadas	41
5.3. Diferencias con IPR	43
5.4. Mezcla de características	43
5.5. Pruebas a nuevos datos	46
5.5.1. Actualizaciones de SwissProt	46
6. Discusión	48
6.1. Secuencias no alineadas por BLAST	48
6.2. Ventajas de BLAST-KNN en casos multiclase	48
6.3. Limitación de SwissProt	49
7. Conclusiones y trabajo futuro	51
Bibliografía	53