KSBi-BIML 2023

Bioinformatics & Machine Learning(BIML) Workshop for Life Scientists, Data Scientists, and Bioinformatians

생물정보학&머신러닝 워크샵(온라인)

질량분석을 활용한 단백체 연구

김민식 _ DGIST





본 강의 자료는 한국생명정보학회가 주관하는 BIML 2023 워크샵 온라인 수업을 목적으로 제작된 것으로 해당 목적 이외의 다른 용도로 사용할 수 없음을 분명하게 알립니다.

이를 다른 사람과 공유하거나 복제, 배포, 전송할 수 없으며 만약 이러한 사항을 위반할 경우 발생하는 **모든 법적 책임은 전적으로 불법 행위자 본인에게 있음을 경고**합니다.

KSBi-BIML 2023

Bioinformatics & Machine Learning (BIML) Workshop for Life Scientists, Data Scientists, and Bioinformatians

안녕하십니까?

한국생명정보학회가 개최하는 동계 교육 워크샵인 BIML-2023에 여러분을 초대합니다. 생명정보학 분야의 연구자들에게 최신 동향의 데이터 분석기술을 이론과 실습을 겸비해 전달하고자 도입한 전문 교육 프로그램인 BIML 워크샵은 2015년에 시작하여 올해로 9차를 맞이하게 되었습니다. 지난 2년간은 심각한 코로나 대유행으로 인해 아쉽게도 모든 강의가 온라인으로 진행되어 현장 강의에서만 가능한 강의자와 수강생 사이에 다양한 소통의 기회가 없음에 대한 아쉬움이 있었 습니다. 다행히도 최근 사회적 거리두기 완화로 현장 강의가 가능해져 올해는 현장 강의를 재개 함으로써 온라인과 현장 강의의 장점을 모두 갖춘 프로그램을 구성할 수 있게 되었습니다.

BIML 워크샵은 전통적으로 크게 인공지능과 생명정보분석 두 개의 분야로 구성되었습니다. 올해 AI 분야에서는 최근 생명정보 분석에서도 응용이 확대되고 있는 다양한 심층학습(Deep learning) 기법들에 대한 현장 강의가 진행될 예정이며, 관련하여 심층학습을 이용한 단백질구조예측, 유전체 분석, 신약개발에 대한 이론과 실습 강의가 함께 제공될 예정입니다. 또한 싱글셀오믹스 분석과 메타유전체분석 현장 강의는 많은 연구자의 연구 수월성 확보에 큰 도움을 줄 것으로 기대하고 있습니다. 이외에 다양한 생명정보학 분야에 대하여 30개 이상의 온라인 강좌가 개설되어 제공되며 온라인 강의의 한계를 극복하기 위해서 실시간 Q&A 세션 또한 마련했습니다. 특히 BIML은 각 분야 국내 최고 전문가들의 강의로 구성되어 해당 분야의 기초부터 최신 연구 동향까지 포함하는 수준 높은 내용의 강의가 될 것입니다.

이번 BIML-2023을 준비하기까지 너무나 많은 수고를 해주신 BIML-2023 운영위원회의 남진우, 우현구, 백대현, 정성원, 정인경, 장혜식, 박종은 교수님과 KOBIC 이병욱 박사님께 커다란 감사를 드립니다. 마지막으로 부족한 시간에도 불구하고 강의 부탁을 흔쾌히 허락하시고 훌륭한 현장 강의와 온라인 강의를 준비하시는데 노고를 아끼지 않으신 모든 연사분께 깊은 감사를 드립니다.

2023년 2월

한국생명정보학회장 이 인 석

질량분석을 활용한 단백체 연구

(이론) Mass Spectrometry-based Proteomics (실습) Proteomics Data Analysis

인간의 DNA에 있는 유전자들은 발달 및 노화 과정 동안, 장기 및 조직의 위치에 따라, 그리고 외 부 환경의 변화에 대응하여 단백질을 만들어 내고 있는 것은 매우 흥미로운 일이다. 이를 통해 다 세포 생물의 하나인 인간 몸속의 수많은 세포가 각기 다른 일을 유기적으로 할 수 있는 것일 것 이다. 우리는 많은 경우 유전적이지 않은 상황으로 인해 DNA의 변형을 맞이하고 이를 통해 세포 에 병인이 발생하여 때로는 결국 죽음에 이르는 병을 얻게 된다.

최근 질량분석법을 기반으로 하는 단백질 집합(통칭 단백체, Proteome)에 대한 연구 기술이 급격 히 발달하고 있으며 가까운 시일 내에 NGS 수준의 방대한 데이터 양을 생산하는 날이 머지 않았 다. 그렇다면 우리는 언제 단백체 기반의 빅데이터 연구를 하게 될까? 나아가서 유전체와 단백체 통합에 대한 활발한 연구를 통해 생명체가 시간적, 그리고 공간적으로 어떻게 외부 환경에 반응하 고, 어떻게 내부적으로 짜여진 프로그램을 영위해 나가는지 이해할 수 있을 것이다. 그러나 단백 체 데이터는 유전체 데이터와는 상이한 방식으로 수집이 되고 이를 이해하는 방법은 매우 다르다. 본 강의에서는 질량분석에 대해 이해하고 단백체 데이터 수집 방식을 공부할 것이며 단백체 데이 터 분석을 위해 사용되는 플랫폼에 대해 경험하고 데이터 처리에 대한 예를 다룰 것이다. 이를 통 해 빅데이터를 빠르고 손쉽게 처리할 수 있는 핵심 역량을 갖추는 것을 목표로 한다.

강의는 다음의 내용을 포함한다:

- Mass Spectrometry 개요와 단백체 실험의 개론
- MS 데이터 수집 방법 및 이해
- 데이터 처리 방법과 이해

* 참고강의교재: Min-Sik Kim et al. Nature 2014

* 교육생준비물: 노트북 (메모리 8GB 이상, 디스크 여유공간 30GB 이상)

* 강의 난이도: 초급

Curriculum Vitae

Speaker Name: Min-Sik Kim, Ph.D.



Personal Info	
Name	Min-Sik Kim
Title	Associate Professor
Affiliation	Department of New Biology, DGIST
Contact Informa	ation
Address	DGIST, 333 TechnoJungang-daero, Dalseong-gun, Daegu
Email	mkim@dgist.ac.kr
Phone Number	053-785-1630

Research Interest

Mass Spectrometry, Proteomics, Systems Biology, Metabolomics, Multi-Omics

Educational Experience

2002	B.S. in Chemistry, Korea University, Korea
2004	M.S. in Physical Chemistry, Korea University, Korea
2013	Ph.D. in Biological Chemistry, Johns Hopkins University School of Medicine, USA

Professional Experience

2013-2016	Postdoctoral fellow, Institute of Genetic Medicine,
	Johns Hopkins University School of Medicine
2016-2018	Assistant Professor, Department of Applied Chemistry, Kyung Hee University
2018-present	Assistant, Associate Professor, Department of New Biology, DGIST

Selected Publications (5 maximum)

- 1. Hyeon, D. Y., Nam, D...., **Kim, M.-S**., ... Hwang, D., Lee, S.-W. (2022) Proteogenomic landscape of human pancreatic ductal adenocarcinoma in an Asian population reveals tumor cell-enriched and immune-rich subtypes. *Nature Cancer*. Accepted.
- Jang, E. W.I, Park, J. H.I, ... Kim, M.-S.* (2022) Cntnap2-dependent molecular networks in autism spectrum disorder revealed through an integrative multi-omics analysis. *Molecular Psychiatry*. Accepted.
- Cha, S.-J., Kim, M.-S., Na, C. H., Jacobs-Lorena, M. (2021) Plasmodium sporozoite phospholipid scramblase interacts with mammalian carbamoyl-phosphate synthetase 1 to infect hepatocytes. *Nature Communications*. 12(1):6773.
- Park, J.-H., Ryu, S. J., ...,, Lee, J. H., Park, J. H., ..., Kim, M.-S.*, Hwang, D.*, Lee, Y.-S.*, and Park, S. C.* (2021) Disruption of nucleocytoplasmic trafficking as a cellular senescence driver. *Experimental & Molecular Medicine*. 53, 1092–1108.
- 5. Huh, S., Hwang, D.*, **Kim MS*** (2020) Statistical modeling for enhancing discovery power of citrullination from tandem mass spectrometry data. *Analytical Chemistry*. 92, 19, 12975–12986.

SBi한국생명정보학회

KSBi-BIML

질량 분석을 활용한 단백체 연구 (이론) Mass Spectrometry-based Proteomics

약력

• 김민식, 이학박사

- 1995-2002 고려대학교 화학과 이학 학사
- 2002-2004 고려대학교 화학과 질량분석학 석사
- 2007-2013 존스홉킨스 의과대학 생화학 박사
- 2013-2016 존스홉킨스 유전체연구소 포스닥
- 2016-2018 경희대학교 응용화학과 조교수
- 2018-2020 DGIST 뉴바이올로지학과 조교수
- 2020-현재 DGIST 뉴바이올로지학과 부교수



질량 분석기 개발의 기초 아이디어



Nobel Prize in Physics (1906)

"in recognition of the great merits of his theoretical and experimental investigations on the conduction of electricity by gases."





J. J. Thomson (1856~1940)





			Carbon 12.011						
피 = 그 새며레 :	교학사 와악 I					소	동위 원소	성 원소의	Ⅱ-3 생명체 구
요.							단소		<u> </u>
표 I-3 성당세 - 원소	180	180	산소		질소	110	130	120	
원소	180	2) ¹ §O	산소) ¹ 30	1§O	질소 ¹ 4N ¹ 9N	¹ ⁴ C	чЗС	١ؤC	
원소 양성자 수	1§0 8	2) ¹ §O 8	산소) ¹ ³ 0 8	^{1§} O 8	질소 ¹ 4N ¹⁵ N 7 7	¹ %C 6	¹ %C 6	¹² 6C 6	양성자 수
표 II-3 정당세 - 원소 양성자 수 중성자 수	¹ §O 8 10	2 1§O 8 10	산소) ¹ ³ O 8 9	1§O 8	질소 ⁴ /N ¹ /9N 7 7 7 8	¹ %C 6 8	¹ %C 6 7	¹ ² C 6 6	양성자 수 중성자 수
표 II-3 정당세 - 원소 양성자 수 중성자 수 전자 수	¹ §O 8 10 8	2 1§0 8 10 8	산소) ¹ 30 8 9 8	1§O 8 8 8	질소 ⁴ N ¹ 9N 777 78 77	⁴⁸ С 6 8 6	¹ 8C 6 7 6	¹ ² C 6 6 6	양성자 수 중성자 수 전자 수



- 탄소, carbon
 - (평균)원자량 12.011
 - ¹²C 98.89%
 - ¹³C 1.11%
 - ¹⁴C 거의 없음



탄소 원자의 (평균)원자량 = 12 X 0.9889 + 13 X 0.0111 = 12.0111



12

Unpublished data

기체 이온의 공간적 트랩핑 기술 개발



Nobel Prize in Physics (1989)

"for the development of the ion trap technique."



Hans G. Dehmelt (1913~2017)

Penning ion trap



Wolfgang Paul (1913~1993)

Paul ion trap



www.youtube.com





저에너지 이온화 기술 개발과 바이오 고분자 분석











	$m/\delta m$	
913	13	Thomson
918	100	Dempster
919	130	Aston
937	2000	Aston
998	8 000 000	Marshall and co-worke
질량분석기	기별 질량분석 스펙트럼	! 분해능 차이
질량분석기	기별 질량분석 스펙트럼	l 분해능 차이
질량분석기	기별 질량분석 스펙트럼	l 분해능 차이
질량분석기	기별 질량분석 스펙트럼 [M+4H] ⁴⁺	! 분해능 차이
질량분석기 100	기별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.54	불해능 차이 ⁵⁹⁶ R=2000
질량분석기	/별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.54	분해능 차이 896 R=2000 TQ or lon trap
질량분석기	/별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.59 918.3986 010	분해능 차이 896 R=2000 TQ or lon trap
2 ジェンク 100 100 50 100 100 100 50 100 100 100 50 100	/별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.59 918.3986 918.1479 918. 918. 918.1479 918. 918.	1 분해능 차이 896 R=2000 TQ or lon trap 6492 R=2000 TOF 8.8999
100 100 50 100 50	1별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.59 918.1479 918. 918.1479 918. 918	396 R=2000 TQ or lon trap 6492 R=2000 TOF 8.8999 919.1505
2 량분석 ス	1별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.3986 918.1479 918.3986 918.3986 918.1986 918.3986 918.3986 918.3986 918.3986 918.3986 918.3986 918.3986	396 R=2000 TQ or lon trap 6492 R=2000 TOF 8.8999 919.1505 6492 R=60000 Orbitrap
2 량분석 ス	1별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.3986 918.1479 918.3986 918.1918 918.3986 918.1918 918.3986 918.3986 918.1918 918.3986 918.3986 918.3986 918.3986 918.3986 918.3986 918.3986	396 R=2000 TQ or lon trap 6492 R=2000 TOF 8.8999 919.1505 6492 R=60000 Orbitrap 8.8999 919.1505
	1별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.3986 918.1479 918.3986 918.3986 918.3986 918.3986 918.3986	B96 R=2000 TQ or lon trap 6492 R=2000 TOF 8.8999 919.1505 6492 R=60000 Orbitrap 8.8999 919.1505
질량분석 7	1별 질량분석 스펙트럼 [M+4H] ⁴⁺ 918.3986 918.1479 918. 918.3986 918. 918.3986 918. 918.3986 918. 918.3986 918. 918.3986 918. 918.3986 918. 918.3986 918. 918.1479 918.6492 918.1479 918.6492	B96 R=2000 TQ or lon trap 6492 R=20000 8.8999 919.1505 6492 R=60000 6492 R=60000 6492 R=60000 6492 R=60000 7000 FT/ICR

Г



Peptide Sequencing







Top-Down Proteomics



Figure 1.23

ESI spectrum of phage λ lysozyme; m/z in Th and the number of charges are indicated on each peak. The molecular mass is measured as being 17828 ± 2.0 Da.



Quantitation

Choice of Quantitation in Proteomics

- Label
 - Metabolic labeling
 - Chemical labeling
- Label-free
 - # spectral counting (ex. # PSM)
 - LC profile

- Model samples (ex, cell)
- Clinical samples (ex, blood)



- 18 -









- 22 -

DI

ТΡ

Е

Ρ

Е

R.I.



- Principle of Mass Spectrometry and Basics of Proteomics
- Applications to different research fields





KSBi-BIML 2022

질량 분석을 활용한 단백체 연구 (실습) Proteomics Data Analysis

약력

• 김민식, 이학박사

- 1995-2002 고려대학교 화학과 이학 학사
- 2002-2004 고려대학교 화학과 질량분석학 석사
- 2007-2013 존스홉킨스 의과대학 생화학 박사
- 2013-2016 존스홉킨스 유전체연구소 포스닥
- 2016-2018 경희대학교 응용화학과 조교수
- 2018-2020 DGIST 뉴바이올로지학과 조교수
- 2020-현재 DGIST 뉴바이올로지학과 부교수





Human Proteome Map and Genome Annotation







CREDIT: JOE SUTLIFF

 \equiv

The shift in thinking from genomics to proteomics comes with an appreciation of the difficulty of the task: Proteins are much more complicated than nucleic acids. Unlike the decoratively challenged DNA, proteins get phosphorylated, glycosylated, acetylated, ubiquitinated, farnesylated, sulphated, linked to glycophosphatidylinositol anchors, and embellished in numerous other ways. A single gene can encode multiple different proteins-these can be produced by alternative splicing of the mRNA transcript, by varying translation start or stop sites, or by frameshifting during which a different set of triplet codons in the mRNA is translated. All of these possibilities result in a proteome estimated to be an order of magnitude more complex than the genome. (So it may be fortunate for proteomicists that humans might have as few as six times the number of genes that yeast have!) What is more, proteins respond to altered conditions by changing their location within the cell, getting cleaved into pieces, and adjusting their stability as well as changing what they bind to (other proteins, nucleic acids, lipids, small molecules, or other ligands). Protein levels often do not reflect mRNA levels (1), and even the presence of an open reading frame does not guarantee protain I actly a single protain may be involved in more th the ovictores of a







Current limitation of proteome analysis

- The peptide sequencing is fully based on a protein sequence database
- Currently most of protein sequencing analyses are based on the bottom-up approach instead of analyzing intact proteins

 What if database is inaccurate?









Evidence of a global transcription of pseudogenes









Post-translational Modifications







He Huang,¹ Benjamin R. Sabari,² Benjamin A. Garcia,³ C. David Allis,² and Yingming Zhao¹ ¹Ben May Department of Cancer Research, The University of Chicago, Chicago, IL 60637, USA ²Laboratory of Chromatin Biology and Epigenetics, The Rockefeller University, New York, NY 10021, USA ³Department of Biochemistry and Biophysics, University of Pennsylvania, Philadelphia, PA 19104, USA

















- Principle of Mass Spectrometry and Basics of Proteomics
- Applications to different research fields



