



## 内生菌 KM-1-2 全基因组 ORFs 信号肽和分泌蛋白预测及功能分析

吕伟强<sup>1,2</sup>, 刘聪<sup>1,2</sup>, 黄丽丽<sup>2,3\*</sup>, 颜霞<sup>1,2\*</sup>

<sup>1</sup>西北农林科技大学生命科学学院, 陕西 杨凌 712100

<sup>2</sup>国家旱区作物逆境生物学国家重点实验室, 陕西 杨凌 712100

<sup>3</sup>西北农林科技大学植物保护学院, 陕西 杨凌 712100

**摘要:**【目的】内生菌普遍存在于植物中,与宿主在长期的进化中形成了互利共生的关系。目前对内生菌和植物之间的互作机制研究较少,为深入了解银杏叶内生菌 KM-1-2 与寄主植物作用机制,本研究对其分泌蛋白进行预测,并明确其特征。【方法】组合使用信号肽分析软件 SignalP,跨膜螺旋结构分析软件 TMHMM 2.0 和 Phobius,蛋白质细胞定位软件 PSORT,亚细胞定位软件 TargetP 和 GPI 锚定位点分析软件 big-PI Predictor,预测 KM-1-2 基因组范围内所有分泌蛋白,定义为分泌组。【结果】KM-1-2 全基因组 5299 条蛋白序列中发现 271 个具有典型信号肽的分泌蛋白,占全基因组的 2.4%;编码这些蛋白的 ORF 最短为 61 bp,最大为 2105 bp,平均为 373 bp;引导它们的信号肽长度分布在 15–37 aa 之间,平均为 24 aa。信号肽中出现频率最高的氨基酸依次为丙氨酸、亮氨酸和缬氨酸,信号肽切割类型多属于 A-X-A 型,即 SPI 切割类型。共 66 个蛋白质有功能描述,其中包括 26 个酶类。这些酶主要包括各种糖苷水解酶、酯酶、蛋白酶、碳氧裂解酶等。【结论】通过上述生物信息学分析方法有效实现了银杏叶内生菌 KM-1-2 分泌蛋白的预测,这些分泌蛋白功能涉及较多的酶类以及其他未知功能,为进一步研究内生菌和植物的互作提供了基础。

**关键词:** 内生菌, 全基因组, 分泌蛋白预测, 信号肽

分泌蛋白通常是由 N 端的信号肽指导通过细胞膜被运输到胞外的正确作用位点。根据信号肽学说,当内质网结合核糖体仍处于游离状态时,即已开始翻译多肽链,并在分泌蛋白 N 端形成一

个长 15–30 个氨基酸的信号肽<sup>[1]</sup>。分泌蛋白应该具有以下特征:(1) 在其 N - 端均具有用于分泌至胞外的信号肽序列;(2) 无跨膜结构域;(3) 无 GPI 锚定位点;(4) 没有将蛋白输送至线粒体或其它胞

基金项目: 国家自然科学基金(31101476, 31171796); 陕西省科学技术研究发展计划(2013K01-45); 杨凌示范区科技计划(2014NY-41)

\*通信作者。黄丽丽, Tel : +86-29-87091312, E-mail : huanglili@nwsuaf.edu.cn; 颜霞, Tel : +86-29-87092262, E-mail : luckyx@126.com

收稿日期: 2016-08-03; 修回日期: 2016-09-28; 网络出版日期: 2016-12-02

内细胞器的预测定位信号<sup>[2]</sup>。满足以上 4 个标准的通常可定义为分泌蛋白编码基因。尽管不同的蛋白信号肽存在差异，但信号肽的基本结构是相似的。信号肽一般有 3 个明显的结构域，即 N 结构域、H 结构域、C 结构域。随着对信号肽研究的深入，人们根据信号肽的氨基酸组成及其所在位置将它划分为 5 种类型<sup>[3-7]</sup>：(1) 分泌信号肽；(2) RR-motif 信号肽；(3) 脂蛋白信号肽；(4) Prephilin-like 信号肽；(5) 细菌素和信息素信号肽。

国外学者利用生物信息学分析软件对杨叶锈菌(*Melampsora* spp.)<sup>[8]</sup>和胚芽乳杆菌(*Lactobacillus plantarum*)<sup>[9]</sup>中所含的分泌蛋白进行预测；国内学者则基于全基因组数据对多杀性巴氏杆菌<sup>[10]</sup>、禾谷炭疽菌<sup>[2]</sup>、西瓜果斑病菌<sup>[11]</sup>、香蕉细菌性软腐病菌<sup>[12]</sup>、玉米弯孢叶斑病菌<sup>[13]</sup>、大丽轮枝菌<sup>[14]</sup>、菜豆根瘤菌<sup>[15]</sup>、葡萄灰链霉菌<sup>[16]</sup>等分泌蛋白进行了预测。然而对植物内生放线菌分泌蛋白的研究尚未见报道，随着银杏叶内生菌 KM-1-2 全基因组序列的测定，对开展该菌分泌蛋白的预测提供了便利条件。外泌蛋白的分析，可以为研究微生物与植物之间、生防菌与病原菌之间互作提供参考。

本研究以银杏叶内生菌 KM-1-2 5299 条序列为基础，基于分泌蛋白所具有的主要特征，利用 SignalP、PSORT、TMHMM、TargetP、Big-PI 等生物信息学分析程序对分泌蛋白进行预测，探究分泌蛋白在内生过程中发挥的作用，以期为后续该菌与宿主的互作机制研究奠定基础。

## 1 材料和方法

### 1.1 数据获取

本实验室前期分离并测序得到的 KM-1-2 ORFs 注释及功能信息，DDBJ/ENA/GenBank 序列

号 MAUN00000000。其中 KM-1-2 共包含 6906 条编号以>KM-1-2 为起始的蛋白质编码 ORFs；将其蛋白组信息保存在 FASTA 格式。

### 1.2 分泌蛋白确定方法(图 1)

**1.2.1 N-端信号肽预测：**利用 SignalP 4.1 (<http://www.cbs.dtu.dk/services/SignalP/>) 对蛋白质组是否有信号肽进行预测分析<sup>[17-20]</sup>。通过神经网络法进行 N 端信号肽及其剪切位点预测，包含 5 个得分参数，即 C 值(剪切位点原始分值)、S 值(信号肽序列分值)、Y 值(C 值几何均值与 S 值的联合得分值)、mean S (S 值的算术均值)、D 值(mean S 值与最大 Y 值的权重均值)。其中 D 值用于区分信号肽(SP='YES')与非信号肽(SP='NO')。本研究使用参数 D 值“YES”，预测蛋白含有 N 端信号肽序列。SignalP 是应用最广泛的预测软件之一，测试发现其对分泌蛋白的预测准确性达 89%，因此可单独用于蛋白分泌组预测。




图 1. 分泌组预测流程

Figure 1. Flowchart of strategy used to identify secretome.

**1.2.2 跨膜区预测：**TMHMM Server V.2.0 (<http://www.cbs.dtu.dk/services/TMHMM/>) 软件预测蛋白的跨膜螺旋结构，排除具有跨膜螺旋结构的蛋白<sup>[21]</sup>。预测蛋白跨膜螺旋的数量(Number of predicted TMHs, PredHel)和跨膜区氨基酸长度(Exp number of AAs in TMHs, ExpAA)，同时给出查询蛋白长度值(len)、前 60 个氨基酸所预测跨膜螺旋数(First60)、及拓扑结构(Topology)等参数。ExpAA 长度大于 18 则证明有跨膜结构或者有信号肽<sup>[22]</sup>。

**1.2.3 胞外定位预测：**PSORT<sup>[23]</sup> (<http://psort.nibb.ac.ip/form.html>) 软件确定这些分泌型信号肽的准确性以及该信号肽切割位点是否可被识别并切割。可预测蛋白定位，并对可能的定位情况进行打分，分值越高定位于该处的可能性越高。本研究使用 extr 值>17，预测蛋白定位于胞外。

**1.2.4 亚细胞定位预测** 利用 TargetP 1.1 Server<sup>[24-26]</sup> (<http://www.cbs.dtu.dk/services/TargetP/>) 预测分泌蛋白进入植物后在植物细胞内的定位，明确哪些蛋白定位于胞外。通过预测的最高值与第二高值之间的差异分值(diff)进行可信度分区，1 代表 diff>0.8，2 代表 0.8>diff>0.6，3 代表 0.6>diff>0.4，4 代表 0.4>diff>0.2，5 代表 diff<0.2。本研究使用参数 Loc 值“S”，预测蛋白含信号肽序列并定位于胞外。

**1.2.5 GPI 锚定位点预测：**利用 big-PI Predictor ([http://mendel.imp.ac.at/sat/gpi/gpi\\_server.html](http://mendel.imp.ac.at/sat/gpi/gpi_server.html)) 在线分析实现蛋白脂质锚定修饰的预测，去除锚定蛋白序列。本研究使用结果为 None potential GPI-modification site，即无膜质结合位点的蛋白序列。

### 1.3 分泌蛋白的功能预测

将获得的分泌蛋白通过 NCBI protein BLAST (<http://blas.ncbi.nlm.nih.gov/Blas.tcgi>) 与数据库中

已知蛋白进行相似性比对，预测分泌蛋白的可能功能，参数默认使用。使用 Blast2go<sup>[27-28]</sup>程序分析酶学分类，GO 注释。

## 2 结果和分析

### 2.1 银杏叶内生菌 KM-1-2 分泌蛋白预测结果

银杏叶内生菌 KM-1-2 共有 5299 条蛋白质序列，首先采用 SignalP V4.1 对全基因 ORFs 序列进行信号肽预测，结果表明 338 个序列在 N 端含有典型的信号肽序列，所占比例为 7.32%。通过 TMHMM V2.0 在线分析上述蛋白的跨膜结构域，结果(图 2)显示有 226 个蛋白不含有跨膜结构域，所占比例为 58.25%；162 个蛋白含有不同数量的跨膜结构域，其中，含有 1 个跨膜结构域的蛋白有 120 条，所占比例为 74.10%；含有 2 个跨膜结构域的为 24 条，所占比例为 14.80%；其余含有多个跨膜结构域的序列共占比例 11.10%。

对于上述不含跨膜结构域的 226 条蛋白序列进行深入分析，排除跨膜结构域定位于膜内的 5 条序列，剩余的 221 条跨膜结构域均定位于膜外。对于只含 1 个跨膜域的蛋白质，其所具有的跨膜结构域位置均位于 N 端，而该区域可能为前期所





图 2. 388 个定位于胞外的蛋白跨膜区预测情况

Figure 2. The transmembrane prediction of 388 extracellular proteins.

预测的信号肽序列。由于 TMHMM V2.0 程序并不能完全对信号肽序列和所属跨膜区序列进行区分，可能误将 N-端信号肽预测为跨膜区，造成预测的假阴性。鉴于此，此次研究将含有 1 次跨膜结构的 120 条序列提交于 Phobius 软件进行深入分析，将其预测含有信号肽的 119 条蛋白序列重新保留而进入后续的分析研究，降低了预测中假阴性的出现。

后续采用 PSORT 软件将上述得到的 345 条序列预测分析，结果分为细胞质型、细胞质膜型、胞外型 3 类。其中胞外型共 149 条，所占比例为 43.20%。同时，使用 Target PV1.1 预测蛋白是否含有转运肽，从而明确蛋白质的细胞定位情况，可归属为线粒体目标肽、叶绿体转运肽以及分泌途径信号肽等，从而有助于将分泌目标为胞内细胞器(线粒体、叶绿体等)的蛋白进行排除。上述蛋白中，含有胞外定位信号、线粒体目标肽、其他定位信号所占比例分别为 85.58%、12.75%、1.67% (图 3)。

利用 big-PI Predictor 对上述 129 条蛋白序列进行 GPI 锚定蛋白预测，由于 GPI 软件预测所需最短序列数为 55，为保证分泌蛋白预测的准确性，所以排除 1 条少于 55 个 aa 的 ORFs。对剩余的 128 条序列进行预测分析，结果显示 128 个蛋白序列均不具有 GPI 锚定位点。




**图 3. 345 个具有典型分泌特征的分泌蛋白的定位**  
Figure 3. Location of 345 secretory proteins with typical characteristics.

通过综合 SignalP 和 TargetP 等诸多生物信息学在线预测分析菌株 KM-1-2 中 5299 条蛋白序列，最终获得 128 条具有 4 个典型特征的分泌蛋白。对上述分泌蛋白氨基酸长度进行分析，结果显示见图 4，这些分泌蛋白多集中于 100–700 aa，所占比例高达 90.60%。该结果表明 KM-1-2 分泌蛋白多属于小型蛋白，所含的氨基酸长度一般较小。

## 2.2 银杏叶内生菌 KM-1-2 分泌蛋白信号肽特征分析

现已明确大多数物种的信号肽主要是通过 5 种类型的信号肽识别位点从而被信号肽酶所识别并被切割，从而使成熟蛋白穿过膜而转运至细胞的不同部位。本研究对 128 个分泌蛋白所含信号肽的氨基酸长度进行分析，结果显示(图 5)，含有信号肽长度为 20–28 个 aa 的蛋白序列数量最多，所占比例为 70.80%。另外，采用 LipoP V1.0 对上述分泌蛋白进行信号肽酶识别位点的预测分析，结果显示，121 个蛋白序列含有 SPI 型信号肽识别位点，4 个含有细菌素-信息素信号肽(CYT 型)，3 个被预测为 SPII。总体分析说明银杏叶内生菌中的分泌蛋白大部分是由 SPI 型信号肽酶进行识别，从而切除信号肽。



**图 4. 分泌蛋白氨基酸长度分析**  
Figure 4. Analysis of secretory protein with different length of amino acid.




图 5. 分泌蛋白信号肽长度分析

Figure 5. Analysis of signal peptide length of secretory protein.

通过对银杏叶内生菌分泌蛋白信号肽的切割位点-3位到+3位进行统计分析,结果显示(表1),位于-3、-2、-1、1、2、3位最多的氨基酸分别为A、A、A、A、A、A,所占比例分别为32.28%、40.94%、29.13%、29.13%、25.98%、36.22%。位于信号肽切割位点之前的-3位、-2位、-1位的氨基酸组成为A-A-A,属A-X-A类型,为SPI型信

号肽识别位点,这与通过LipoP预测结果一致。

同时,对组成蛋白质的20种氨基酸在信号肽中的分布情况进行统计分析见图6,结果显示A所占比最大,为25.81%,其次为L,所占比例为15.28%,T、V、G、R、S,所比例分别为10.04%、9.94%、7.63%、6.81%、5.28%。

### 2.3 功能注释

在NCBI中通过Protein-BLAST将最后得到的128个分泌蛋白序列与已知蛋白进行同源比对。有2个蛋白未BLAST到任何蛋白(1.0E-3),占所有蛋白数量的1.56%。比对的E-value数值分布在1.9E-179和3.2E-8之间。BLAST相似度分布在57.20%–100%,其中大于70%相似度的序列占87.50%,所以本研究中对蛋白质的功能鉴定有较高的可靠性。使用Blast2Go分析这些分泌蛋白的物种分布,其中所属物种数量较多的分别为*Streptomyces* sp. (51.60%)、

表 1. 分泌蛋白信号肽切割位点氨基酸分布情况

Table 1. Amino acid frequency and distribution in signal peptide cleavage sites of secretory proteins/%

Types of amino acids	Amino acid distribution in cleavage sites					
	-3	-2	-1	1	2	3
A	32.28	40.94	29.13	29.13	25.98	36.22
G	14.17	11.81	10.24	12.60	11.02	6.30
L	13.39	9.45	16.54	11.02	8.66	11.02
T	11.02	7.87	9.45	8.66	11.81	8.66
V	10.24	7.09	7.09	5.51	5.51	5.51
P	7.87	4.72	7.09	9.45	12.60	8.66
S	2.36	9.45	3.94	4.72	6.30	2.36
F	1.57	0.79	0.79	0.79	0.79	1.57
Q	1.57	3.15	3.15	2.36	1.57	1.57
R	1.57	0.00	0.00	1.57	2.36	2.36
D	0.79	1.57	3.15	3.15	1.57	2.36
E	0.79	0.79	1.57	1.57	0.79	4.72
H	0.79	0.00	0.79	3.15	2.36	3.15
I	0.79	0.00	0.79	1.57	2.36	0.00
N	0.79	0.79	0.00	1.57	0.00	1.57
M	0.00	0.79	2.36	0.79	1.57	0.00
W	0.00	0.79	0.00	0.79	1.57	1.57
C	0.00	0.00	1.57	0.00	0.00	0.79
K	0.00	0.00	1.57	0.79	1.57	0.79
Y	0.00	0.00	0.79	0.79	1.57	0.79




图 6. 20 种氨基酸在分泌蛋白信号肽中所占比例情况  
Figure 6. The frequency of 20 amino acid residues of signal peptides in secretory proteins.

*Streptomyces xiamenensis* (8.72%)、*Streptomyces avicenniae* (2.66%)、*Streptomyces specialis* (2.41%)。此外 Blast2Go 得到的 Mapping 和 Annotation 的蛋白分别为 66 和 59 条，占蛋白数量的 51.50% 和 46.10%。

通过 Blast2GO 对蛋白序列进行分析，共有 66 个蛋白有 GO 注释，统计第 4 层 GO 数据，共得到 294 条 GO 术语信息，其中包含生物途径(图 7)(biologic process) 104 条，分子功能 67 条 (molecular function)，细胞组件 8 条 (cellular component)。生物途径中最多的是大分子化合物代谢(30 条)、碳水化合物代谢(20 条)、有机物分解代谢(13 条)。分子功能(图 8)中最多的是水解肽酶活性(14 条)、丝氨酸蛋白酶活性(14 条)、蛋白酶活性(8 条)。在细胞组件(图 9)中最多的是病毒衣壳(3 条)、细胞外周(2 条)。

#### 2.4 胞外酶的种类

除重复与假定蛋白外，共得到 26 个蛋白属于酶类。这些酶类仅占所有预测的分泌蛋白总数的 20.50%，它们的功能分布见图 10。




图 7. KM-1-2 分泌蛋白组生物途径分析  
Figure 7. Biological pathway analysis of KM-1-2 secretome.




图 8. KM-1-2 分泌蛋白组分子功能分析

Figure 8. Molecular function analysis of KM-1-2 scretome.

银杏叶内生菌 KM-1-2 胞外分泌酶类分布较为广泛，其中属于水解酶类(EC 3.)的比例最高，达到 96%；氧化还原酶类和转移酶类分别占 4.0%。未发现氧化还原酶类(EC 1.)、转移酶类(EC 2.)、异构酶类(EC 3.)和连接酶类(EC 4.)。在水解酶类中 EC 3.1.、EC 3.2.、EC 3.4.、EC 3.5. 和 EC 3.6. 分别作用于酯键、糖苷键、碳氮键、羧酸酐键。




图 9. KM-1-2 分泌蛋白组细胞组件分析

Figure 9. Cells component analysis of KM-1-2 scretome.




图 10. KM-1-2 分泌蛋白组酶学分类分析

Figure 10. Scretome enzymology classification analysis.

### 3 讨论

分泌蛋白是指由细胞合成并分泌到胞外的蛋白质，可以分为两大类。一类是经典分泌蛋白(classical secreted protein)，另一类为非经典分泌蛋白(non-classical secreted protein)。非经典途径分泌蛋白缺少常规的信号肽，不依赖内质网-高尔基体的膜分泌系统，目前对这类分泌蛋白进行预测的软件较少，常用的预测软件有 SecretomeP 2.0，SOSUI-GramN，NCClassG+可以分析非经典分泌蛋白<sup>[15]</sup>。但这类分泌蛋白只占少数，本研究主要考

虑的是经典途径分泌的蛋白，通过蛋白 N 端信号肽来预测分泌蛋白。

对分泌蛋白信号肽分析和跨膜预测的软件众多，不同软件的算法不一致，这就导致了不同软件预测的分泌蛋白有一定的差别，采用多个软件对基因组蛋白同时分析，可以有效地提高预测的准确性。将个软件按照预测的结果来分类，可分为如下几类：(1) 蛋白信号肽及其切割位点预测，常见的软件如 SignalP，其他功能类似的软件有 Phobius，SigCleave，PredSI 等；(2) 跨膜蛋白预测，常见的软件有 TMHMM，TMpred；(3) 蛋白亚细胞定位预测，常见的如 ProtComp，TargetP，PSORT 等。综合已有文献报道的分泌蛋白软件预测使用情况，SignalP 对信号肽预测准确度为 96%，TMHMM 对跨膜蛋白预测的准确度高达 97%，而

TargetP 对蛋白质亚细胞定位预测的准确度也高达 90% (表 2)。本研究结合分泌蛋白的特征，采用 6 种生物信息软件结合预测，提高了预测的准确度，使得预测结果更为可靠。

采取组合法对 KM-1-2 的全基因组序列进行预测分析，共得到 128 条分泌蛋白序列，占全基因组的 2.4%。通过对蛋白功能的预测进行分类，结果发现，KM-1-2 胞外分泌蛋白含有丰富的糖苷水解酶、酯酶、蛋白酶等胞外水解酶系。分析 KM-1-2 不同类型的信号肽结构和数量，并将这些数据与其他细菌和真菌的分析结果进行比较 (表 3)，在这 4 种菌中，均未发现 Preplilin-like 信号肽，而其它类型的信号肽含量均有明显差异。说明不同细菌或真菌的信号肽酶组成、蛋白分泌途径确实存在差异。

表 2. 分泌蛋白预测程序

Table 2. The programs for the prediction of secretory protein

Prediction algorithms	Objects predicted	Accuracy/%	Applicable organisms
SignalP V4.1	N-terminal signal peptides	96	Gram-positive bacteria Gram-negative bacteria Eukaryotes
	Transmembrane domains	97–98	Non-plant
	Prediction of protein localization sites	86	Gram-positive bacteria Gram-negative bacteria Yeast, Animal, Plant
Big-PI predictor	GPI-anchor site	>80	Metazoa, Protozoa
TargetP V1.1	Mitochondrial or other localization sequence	90	Non-plant Plant

表 3. 四种微生物基因组中不同类型信号肽出现的频率比较

Table 3. Frequency of different type signal peptide in 4 genome of microorganisms

Strains	SPI/%		SII/%	CYT/%
	Sec-type	RR-motif		
KM-1-2	82.00	12.50	2.30	3.20
<i>Pseudomonas syringae</i> pv. <sup>[30]</sup>	72.00	11.80	16.20	0
<i>Ralstonia solanacearum</i> GMI1000 <sup>[31]</sup>	91.90	5.70	2.40	0
<i>Trichoderma reesei</i>	93.90	0.70	5.40	0

单纯地以试验手段去捕获生物中重要蛋白并进一步深入研究是十分有限的。通过生物信息学的手段可以高通量地获悉生物中某一类型的重要蛋白，并在此基础上进一步分选以获得感兴趣的蛋白，是一种快速而有效的方法。众多的软件已经被用于最初的对所有预测蛋白的功能分析，并已证实十分有效。

目前，已经有多个物种开展了分泌蛋白功能预测分析。唐雯等<sup>[29]</sup>发现里氏木霉分泌蛋白中64%是水解酶，包括糖苷酶（38.78%）、蛋白酶（14.29%）和脂类水解酶（3.74%）等，其中糖苷水解酶占很大比例，包括很多与纤维素、几丁质等多糖降解相关的酶。王海霖等<sup>[17]</sup>发现灰葡萄孢菌367个蛋白质有功能描述，其中包括214个酶类，这些酶主要包括各种糖苷水解酶、酯酶、蛋白酶、多糖聚合酶、氧化还原酶、角质酶等。韩长志等<sup>[3]</sup>发现禾谷炭疽菌具有预测功能的蛋白为330个，其功能较多的集中于酶类，包括α-半乳糖苷酶、β-木聚糖酶、β-木糖苷酶等。本研究中，通过对生防放线菌KM-1-2分泌蛋白组功能预测，发现它们主要集中在糖苷水解酶、酯酶、蛋白酶等水解酶类，这与里氏木霉分泌蛋白的功能较为相似。内生菌分泌蛋白组中水解酶的存在是否与它的内生性有关还有待进一步实验的证明。

## 参 考 文 献

- [1] Von Heijne G. Life and death of a signal peptide. *Nature*, 1998, 396(6707): 111–113.
- [2] Han CZ. Prediction for secreted proteins from *Colletotrichum graminicola* genome. *Biotechnology*, 2014, 24(2): 36–41. (in Chinese)
- 韩长志. 全基因组预测禾谷炭疽菌的分泌蛋白. 生物技术, 2014, 24(2): 36–41.
- [3] Yan SM, Wu G. Signal peptide of cellulase. *Applied Microbiology and Biotechnology*, 2014, 98(12): 5329–5362.
- [4] Zhang Y, Yang J, Liu L, Su Y, Xu L, Zhu YY, Li CY. Analysis of secretory proteins in the genome of the plant pathogenic fungus *Botrytis Cinerea*//Li DL, Liu YD, Chen YY. Computer and Computing Technologies in Agriculture IV: IFIP Advances in Information and Communication Technology. Berlin Heidelberg: Springer, 2010, 344: 227–237.
- [5] Zhang SW, Zhang TH, Zhang JN, Huang YF. Prediction of signal peptide cleavage sites with subsite-coupled and template matching fusion algorithm. *Molecular Informatics*, 2014, 33(3): 230–239.
- [6] Ng SYM, VanDyke DJ, Chaban B, Wu J, Nosaka Y, Aizawa SI, Jarrell KF. Different minimal signal peptide lengths recognized by the archaeal preprolin-like peptidases FlaK and PibD. *Journal of Bacteriology*, 2009, 191(21): 6732–6740.
- [7] Tjalsma H, Bolhuis A, Jongbloed JDH, Bron S, Van Dijken JM. Signal peptide-dependent protein transport in *Bacillus subtilis*: a genome-based survey of the secretome. *Microbiology and Molecular Biology Reviews*, 2000, 64(3): 515–547.
- [8] Joly DL, Feau N, Tanguay P, Hamelin RC. Comparative analysis of secreted protein evolution using expressed sequence tags from four poplar leaf rusts (*Melampsora* spp.). *BMC Genomics*, 2010, 11: 422.
- [9] Mathiesen G, Sveen A, Brurberg MB, Fredriksen L, Axelsson L, Eijsink VGH. Genome-wide analysis of signal peptide functionality in *Lactobacillus plantarum* WCFS1. *BMC Genomics*, 2009, 10: 425.
- [10] Peng Z, Liang W, Liu WJ, Xu ZF, Tan C, Wu B, Zhou R, Chen HC. Prediction and analysis of secreted proteins encoding genes in genome of *Pasteurella Multocida* HN06. *Progress in Veterinary Medicine*, 2015, 36(12): 6–10. (in Chinese)  
彭忠, 梁婉, 刘文静, 徐卓菲, 谭臣, 吴斌, 周锐, 陈焕春. 多杀性巴氏杆菌HN06基因组分泌蛋白的预测与分析. 动物医学进展, 2015, 36(12): 6–10.
- [11] Pan H, Gao TY, Wu MD, Yang L, Zhang J, Li GQ. Screening and functional prediction of type I secretory proteins in *Acidovorax citrulli* AAC00-1. *Journal of Huazhong Agricultural University*, 2015, 34(3): 27–35. (in Chinese)  
潘宏, 高天一, 吴明德, 杨龙, 张静, 李国庆. 西瓜果斑病菌T2SS分泌蛋白的筛选和功能预测. 华中农业大学学报, 2015, 34(3): 27–35.
- [12] Xiao WC, Fan HY, Bai TT, Wang W, Li HP. Prediction and analysis of the signal peptide and secreted proteins in soft rot bacteria XJ8-3-3 genome ORFs of banana. *Journal of Fruit Trees*, 2014, 31(6): 1057–1064. (in Chinese)

- 肖文超, 范会云, 白亭亭, 王婉, 李华平. 香蕉细菌性软腐病菌 XJ8-3-3 基因组中 ORFs 的信号肽及分泌蛋白功能预测分析. *果树学报*, 2014, 31(6): 1057–1064.
- [13] Gao JX, Gao SG, Li YQ, Cheng J. Genome-wide prediction and analysis of the classical secreted proteins of *Curvularia lunata*. *Journal of Plant Protection*, 2015, 42(6): 869–876. (in Chinese)
- 高金欣, 高士刚, 李雅乾, 陈捷. 玉米弯孢叶斑病菌全基因组分泌蛋白的预测与分析. *植物保护学报*, 2015, 42(6): 869–876.
- [14] Tian L, Chen JY, Chen XY, Wang JN, Dai XF. Prediction and analysis of *Verticillium dahliae* VdLs.17 secretome. *Scientia Agricultura Sinica*, 2011, 44(15): 3142–3153. (in Chinese)
- 田李, 陈捷胤, 陈相永, 汪佳妮, 戴小枫. 大丽轮枝菌 (*Verticillium dahliae* VdLs.17) 分泌组预测及分析. *中国农业科学*, 2011, 44(15): 3142–3153.
- [15] Zhang W, Pan W, Ma JT, Guo T. Genome-wide prediction and analysis of the non-classical secreted proteins of *Rhizobium etli* CFN42. *Journal of Dali University*, 2015, 14(6): 45–48. (in Chinese)
- 张武, 潘伟, 马金田, 郭涛. 菜豆根瘤菌 CFN42 全基因组非经典分泌蛋白的预测与分析. *大理学院学报*, 2015, 14(6): 45–48.
- [16] Wang HL, Ge WQ, Guo R, Suo YP, Cheng FS. Prediction and analysis of secretome proteins in *Botrytis cinerea*. *Journal of Qingdao Agricultural University (Natural Science)*, 2015, 32(3): 174–179. (in Chinese)
- 王海霖, 葛文谦, 郭瑞, 索一平, 程凡升. 葡萄灰霉病菌胞外分泌蛋白质组的功能预测分析. *青岛农业大学学报(自然科学版)*, 2015, 32(3): 174–179.
- [17] Petersen TN, Brunak S, Von Heijne G, Nielsen H. SignalP 4.0: discriminating signal peptides from transmembrane regions. *Nature Methods*, 2011, 8(10): 785–786.
- [18] Emanuelsson O, Brunak S, Von Heijne G, Nielsen H. Locating proteins in the cell using TargetP, SignalP and related tools. *Nature Protocols*, 2007, 2(4): 953–971.
- [19] Melhem H, Min XJ, Butler G. The impact of SignalP 4.0 on the prediction of secreted proteins//Proceedings of the 2013 IEEE Symposium on Computational Intelligence in Bioinformatics and Computational Biology. Singapore: IEEE, 2013: 16–22.
- [20] Mak MW, Wang W, Kung SY. Fusion of conditional random field and signalP for protein cleavage site prediction[C]//Proceedings of 2009 APSIPA Summit and Conference. Sapporo, Japan: APSIPA, 2009: 716–721.
- [21] Chen YJ, Yu P, Luo JC, Jiang Y. Secreted protein prediction system combining CJ-SPHMM, TMHMM, and PSORT. *Mammalian Genome*, 2003, 14(12): 859–865.
- [22] Xu C, Chen H, Gleason ML, Xu JR, Liu HQ, Zhang R, Sun GY. *Peltaster fructicola* genome reveals evolution from an invasive phytopathogen to an ectophytic parasite. *Scientific Reports*, 2016, 6: 22926.
- [23] Nakai K, Horton P. PSORT: a program for detecting sorting signals in proteins and predicting their subcellular localization. *Trends in Biochemical Sciences*, 1999, 24(1): 34–35.
- [24] Jaramillo VDA, Sukno SA, Thon MR. Identification of horizontally transferred genes in the genus *Colletotrichum*, reveals a steady tempo of bacterial to fungal gene transfer. *BMC Genomics*, 2015, 16: 2.
- [25] Klee EW, Ellis LBM. Evaluating eukaryotic secreted protein prediction. *BMC Bioinformatics*, 2005, 6: 256.
- [26] Emanuelsson O, Nielsen H, Brunak S, Von Heijne G. Predicting subcellular localization of proteins based on their N-terminal amino acid sequence. *Journal of Molecular Biology*, 2000, 300(4): 1005–1016.
- [27] Conesa A, Götz S, García-Gómez JM, Terol J, Talón M, Robles M. Blast2GO: a universal tool for annotation, visualization and analysis in functional genomics research. *Bioinformatics*, 2005, 21(18): 3674–3676.
- [28] Conesa A, Götz S. Blast2GO: a comprehensive suite for functional analysis in plant genomics. *International Journal of Plant Genomics*, 2008, 2008: 619832.
- [29] Tang W, Yan M. Prediction and analysis of the secreteomic in *Trichoderma reesei*. *Acta Microbiologica Sinica*, 2008, 48(4): 473–479. (in Chinese)
- 唐雯, 严明. 里氏木霉(*Trichoderma reesei*)分泌组的预测及分析. *微生物学报*, 2008, 48(4): 473–479.
- [30] Liu YT, Li ZY, Zhu YY, Li CY, Li YZ. Analysis of the coding region for signal peptide-containing proteins in *Pseudomonas syringae* pv. *tomato* Genome. *Hereditas (Beijing)*, 2005, 27(6): 959–964. (in Chinese)
- 刘雅婷, 李正跃, 朱有勇, 李成云, 李永忠. 植物病原细菌 *Pseudomonas syringae* pv. *tomato* 基因组中的信号肽分析. *遗传*, 2005, 27(6): 959–964.
- [31] Huang JL, Wu JZ, Xiao CG, Li CJ, Wang GX. Analysis of signal peptides of the secreted proteins in *Ralstonia solanacearum* GMI1000. *Hereditas (Beijing)*, 2007, 29(11): 1409–1416. (in Chinese)
- 黄俊丽, 吴金钟, 肖崇刚, 李常军, 王贵学. 植物病原细菌 *Ralstonia solanacearum* GMI1000 中分泌蛋白信号肽分析. *遗传*, 2007, 29(11): 1409–1416.

# Genome-wide prediction and analysis of the secretory proteins and ORFs signal peptide of ginkgo endophyte KM-1-2

Weiqiang Lü<sup>1,2</sup>, Cong Liu<sup>1,2</sup>, Lili Huang<sup>2,3\*</sup>, Xia Yan<sup>1,2\*</sup>

<sup>1</sup> College of Life Sciences, Northwest A&F University, Yangling 712100, Shaanxi Province, China

<sup>2</sup> State Key Laboratory of Crop Stress Biology for Arid Areas, Yangling 712100, Shaanxi Province, China

<sup>3</sup> College of Plant Protection, Northwest A&F University, Yangling 712100, Shaanxi Province, China

**Abstract:** [Objective] Endophytes are widespread in plants and build long-term mutually beneficial symbiotic relationship with the host. However, the mechanism of their interactions with the host needs further study. To explore the mechanism of endophytic bacterium ginkgo endophyte KM-1-2, we managed to forecast its secretory proteins based on its genome and explicit characteristics. [Methods] Signal peptide analysis software SignalP, transmembrane helical structure analysis software TMHMM and Phobius, cells position software PSORT, subcellular localization software TargetP and GPI anchor site analysis software big-PI Predictor were used to predict the scope of all secreted proteins, which were defined as secretome. [Results] Altogether 128 typical signal peptide secretory proteins were screened out of 5299 protein sequences in KM-1-2 genome, accounting for 2.4% of the whole genome. The shortest ORF encoding these proteins is 61 bp, the longest one is 2105 bp and the average is 373 bp. The length of the signal peptide guiding secretory protein was distributed between 15 to 37 aa, with the average length of 24 aa. Amino acid with the highest present frequency of signal peptide in proper order is alanine, leucine and valine. The type of signal peptide cleavage belongs to A-X-A which named SPI cleavage type. Among the total secretory proteins 66 pieces have functional description and 26 pieces were enzymes. These enzymes mainly include glycoside hydrolase, esterase transferase, REDOX enzyme and carbon oxygen lyase. [Conclusion] The predicted secretory proteins of *Streptomyces lavendulae* KM-1-2 were achieved through bioinformatics analysis. These secretory proteins involved some enzymes and other unknown functions. This result laid the foundation for further study between endophyte and host.

**Keywords:** endophyte, whole-genome, secretory protein, signal peptide

(本文责编: 李磊)

Supported by the National Natural Science Foundation of China (31101476, 31171796), by the Science Technology Research and Development Program of Shaanxi Province (2013K01-45) and by the Science and Technology Program of Yangling Demonstration Zone (2014NY-41)

\*Corresponding author. Lili Huang, Tel: +86-29-87091312, E-mail: huanglili@nwsuaf.edu.cn; Xia Yan, Tel: +86-29-87092262, E-mail: luckyx@126.com

Received: 3 August 2016; Revised: 28 September 2016; Published online: 2 December 2016