

オリジナル DB の作成・更新方法

Mascot Server においてオリジナルのデータベースを作成し検索に利用できるようにする方法 と、作成・データベース構築後にデータベースの内容を更新する方法について記します。作成 方法は様々な方法がありますが、ここではテキストエディタを使ってデータベースファイルを ご自身で作成する方法について説明します。そのほかの作成方法についてはデータベース管理 マニュアル(<u>http://www.matrixscience.co.jp/supportpdf/MASCOTServer_ver26_sequencedbmanage.pdf</u>)の P.19~をご参照ください。

作成手順ですが、まず MASCOT サーバーのデータベース設定の新規作成を開始して途中まで 進め、続いて指定フォルダ内でデータベースファイルを作成してから設定の続きを再開し、完了 させます。

一度設定したオリジナルデータベースの内容を更新したい場合は、ファイルの中身を変更し 上書き保存するだけで自動的に MASCOT 用のデータベースも更新されます。

1. MASCOT データベース設定の新規作成

<u>1-1. Database Manager ページ で新規データベースの作成(途中まで)</u>

Home -> Configuration Editor -> Database Manager ページを開きます。







Database Manager 画面で、左フレームにある「Fasta」欄 「Create new」をクリックします。



Database の名称(Database name)を入力、種類として「New custom definition」を選択し、「Next」ボタンをクリックします。





「Database type」でアミノ酸配列か塩基配列かを選びます(下図例ではアミノ酸を選択しています)。選択後、「Next」ボタンを押します。



今回は自分でファイル作成する状況を想定した手順書なので、×「Download or copy files automatically」でなく、〇「Upload or copy files manually」を選択します。選択後、「Create」 ボタンを押します。





ファイルの準備の仕方を選びます。今回は「Copy files manually」を選択後、「Next」ボタンを 押します。



ここまででひとまず設定を中断します。図のように、所定の場所にデータベースのファイルが なく、所定のフォルダにデータベースファイルをコピーするよう促される画面が表示されます。





<u>1-2. FASTAファイルの作成</u>

MASCOT インストールフォルダ内の、sequence フォルダに、新たに作成したデータベース名の フォルダ (例では「OriginalDB」)がMASCOTによって自動的に作成されています。このフォルダ を開き、フォルダ内にある current フォルダをさらに開いてください。



current フォルダ内に、データベースファイルを作成します。 操作)フォルダ内で右クリック、新規作成→テキストファイル

ファイル名は、「(DB名)_(任意の文字列).fasta」という名称にします。 例) OriginalDB_20210412.fasta

[次頁に続きます]



🥘 OriginalDB_20210	412.fasta - メモ帳			_		\times
 ファイル(<u>E</u>) 編集(<u>E</u>) 書:	式(<u>O</u>) 表示(<u>V</u>) ヘルプ(<u>H</u>)					
>IDOOO1 ProteinA						~
PLEASEENTERAASEQ]					
>IDOOO2 BSA						
MKWVTFISLLLLFSSA	YSRGVFRRDTHKSEIAHRFI	KDLGEEH	FKGLVLIA			
FSQYLQQCPFDEHVKL	VNEL TEFAK TOVADESHAGO	DEKSLHT	LFGDELCK			
	KUEPERNECELSHKUUSPUL	_PKLKPU	PNILUDEF			
INAUENNEWGNILIEIA	KRHPTETAPELLTTANKTNU	JVFUEUU AWQVADI				
	ECCHGDI I ECADDRADI AKY	Y I CONOD	TISSKI KE			
CCDKPLLEKSHCIAEV	EKDAIPENLPPLTADFAED	KDVCKNY	QEAKDAFL			
GSFLYEYSRRHPEYAV	SVLLRLAKEYEATLEECCA	KDDPHAC	YSTVFDKL			
KHLVDEPQNLIKQNCD	QFEKLGEYGFONALIVRYTF	RKVPQVS	TPTLVEVS			
RSLGKVGTRCCTKPES	ERMPCTEDYLSLILNRLCVL	HEKTPV	SEKVTKCC			
TESLVNRRPCFSALTPDETYVPKAFDEKLFTFHADICTLPDTEKQIKKQT						
ALVELLKHKPKATEEU	LKTYMENEVAEVUKUUAAUL	JKEAUFA	VEGPKLVV			
STUTALA						
MKWVTEISLLLESSA	YSRGVERRDTHKSE LAHREL	KDL GEEH	EKGLVLIAESQYLQQC	PEDEH	VKL VNEL	
TEFAKTCVADESHAGC	EKSLHTLFGDELCKVASLR	ETYGDMA	DCCEKQEPERNECFLS	HKDDSF	PDLPKLK	
PDPNTLCDEFKADEKK	FWGKYLYE I ARRHPYFYAPE	ELLYYAN	KYNGVFQECCQAEDKG	ACLLP	<pre><ietmre< pre=""></ietmre<></pre>	
KVLTSSARQRLRCASI	QKFGERALKAWSVARLSQKF	FPKAEFV	EVTKLVTDLTKVHKEC	CHGDLI	_ECADDR	
ADLAKYICDNQDTISS	KLKECCDKPLLEKSHCIAE	VEKDAIP	ENLPPLTADFAEDKDV	CKNYQE	EAKDAFL	
GSFLYEYSRRHPEYAV	SVLLRLAKE YEATLEECCA	KUUPHAC	YSTVFUKLKHLVDEPQ	NLIKQI	NCUQFEK	
LGEYGFUNALIVRYIR	KYPUYSTPTLYEYSKSLGKY IDDOCESNI TDDETVVDV AFT		KPESEKMPUTEDYLSL	TENKEL DEVENSE	ЗУЦНЕК І ЕГТИЦИЮ	
KATEEQLKTVMENFVA	FVDKCCAADDKEACFAVEG	PKLVVST	QTALA	UTALVI		\sim
	26 行、48 列	100%	Windows (CRLF)	UTF-8	}	

各タンパク質情報の入力方法は以下の通りです。

- 以後スペースを入れずにデータベースの ID を記入します。次の半角スペースまでがすべて ID として認識されます。各エントリーでこの ID を重複させないでください。例では、最初 のエントリーの ID として" ID0001" と記入していますが、以降 ID で ID0001 を使うと エラーになりますのでご注意ください。ID はどのような記述でも問題ありませんが、 長すぎると検索速度が低下するので、重複しない限りで短くしてください。ID 入力後に半角 スペースを入力します。
- 半角スペースの次に、タンパク質の名前などの情報を入れます。最初のエントリーの例では 「ProteinA」と入力しています。最初のスペース以降は複数個のスペースが使用されても 問題ありません。
- 続けて改行をし、ID0001のアミノ酸配列を入力します。アミノ酸配列部分は任意に改行を 入れても問題ありません。(ID0002 と ID0003 を比較してください。)次のエントリーの 始まりを示す、">"までがすべて前エントリーのアミノ酸配列と認識されます。

なお例ではアミノ酸配列を入力しましたが、塩基配列でも問題ありません。ただし塩基配列の 場合は既に設定した項目である"database type"の選択が"Amino acid" でなく"Nucleic Acid" となりますので注意してください。

データベースの入力を終えたら、ファイルを保存してください。



<u>1-3. Database Manager 設定(中断箇所からの続き)</u>

1-1の最後の過程の画面を改めて見ると、1-2 で作成されたファイルが画面内で認識され、設定 の続きを行うためのボタン「Edit Configuration」が出ていますのでこのボタンを押して次の 画面を開きます(下図)。もし「Edit Configuration」ボタンが画面に出ず、1-1 の最後の画面 のままである場合、ファイル名の付け方やファイルの場所を間違えている可能性があります。 もう一度ファイル名とファイルが置かれている場所をご確認ください。



データベースの、ID(Accession)部分、Description 部分を FASTA 先頭行から抜き出すための Parse Rule 定義を行います。

まず ID(Accession)部分の抜出ルールを設定するため、「Accession parse rule」下の「Choose」 ボタンを押します。



ここでは FASTA の先頭行のうち、1 番目に注目します(下図赤線)。「ID0001 ProteinA」と ありますが、このうち「ID0001」の部分を ID(Accession)としたいとします。 MASCOT が、候補となる Parse Rule を自動的に左側にリストアップし、そのルールを適用した 場合の実際の ID (Accession)の例が右側に表示されています。ここでは目的としている 抜き出し方である「ID0001」(下図青線)となっている、上から三番目か四番目の抜出ルールを 選びます(上の赤丸)。どちらかをクリックして**ラジオボタンを選択**し、「Choose」ボタンを 押します。





Choose ボタンを押すと元の画面に戻ります。「Accession parse rule」の下には、先ほど選択し た Parse rule が表示されています(下図の上赤丸)。続いて、Description 部分の抜出ルール を設定するため、「Description parse rule」下の「Choose」ボタンを押します。



先程のAccessionの設定同様、まず FASTA の先頭行のうち 1 番目に注目します(下図赤線)。「ID0001 ProteinA」の、「ProteinA」の部分を Description とします。MASCOT が候補となる Parse Rule を左側に、そのルールを適用した場合の実際の Description の例が右側に表示され ています。抜き出し方が「ProteinA」(下図青線)となっている、一番上の抜出ルールのライ塩ボ タンをクリックしてラジオボタンを選択し「Choose」ボタンを押します。





Description にも新たな Parse rule が入力されているのを確認したのち、画面最下部の「Next」ボタンを押してください。



続いて現れる設定画面について、今回の例ではデフォルト値から変更する必要はありません。 画面最下部の「Save and Finish」ボタンを押します。





最後に設定内容を確認する画面が現れます。このままこのデータベースを使用可能な状態と

するには「Activate」ボタンを押します。





1-4. データベース構築の確認

新規に作成したデータベースが正しく認識されているか、確認をします。

Database Status 画面にて、先ほど作成した DB が新たに追加され、Status が"In

Use"となっているかを確認してください(下図)また、サンプルデータなどで検索テストを

行い、実際に検索がうまくいくかどうかをご確認ください。

Mascot s × Mascot s × Mascot c × Mascot c × + ×	
← → C ▲ 保護されていない通信 bell/mascot/x-cgi/ms-statu 図 Q ☆ 第 8 :	
Name = <u>PRIDE_Contaminants</u> Family = C:/inetpub/mascot/sequence/PRIDE_Contaminants/current/PRIDE_Cont Filename = PRIDE_Contaminants_20160908.msp Pathname = C:/inetpub/mascot/sequence/PRIDE_Contaminants/current Status = In use <u>Statistics</u> Compression warnings Recompress file State Time = Tue Apr 13 09:33:38	•
Name = <u>SwissProt</u> Family = C:/inetpub/mascot/sequence/SwissProt/current/SwissProt_*.fasta Filename = SwissProt_2020_05.fasta Pathname = C:/inetpub/mascot/sequence/SwissProt/current/SwissProt_2020_ Status = In use <u>Statistics Compression warnings Unidentified taxonomy Recompres</u> State Time = Tue Apr 13 09:33:38	
Name = <u>UP5640_H_sapiens</u> Family = C:/inetpub/mascot/sequence/UP5640_H_sapiens/current/UP5640_H_sa Filename = UP5640_H_sapiens_20201007.fasta Pathname = C:/inetpub/mascot/sequence/UP5640_H_sapiens/current/ Status = In use <u>Statistics Recompress file</u> State Time = Tue Apr 13 09:33:38	
Name = <u>OriginalDB</u> Family = C:/inetpub/mascot/sequence/OriginalDB/current/OriginalDB_*.fast Filename = OriginalDB_20210412.fasta Pathname = C:/inetpub/mascot/sequence/OriginalDB/current/OriginalDB_2 Status II use <u>Statistics Recompress file</u> State Time = Torien 13 11:20:04 # searches = 0 Mem mapped = YES Request to mem map = YES Request unmap = NO Mem locked = NO Number of threads = -1 Current = YES Type = Amino acid	

なお、下図のように Status が "In use"以外の表示となっている場合は、恐れ入りま すがそのメッセージ内容と、"check error log"をクリックし表示されているデータベース 構築時当日のエラー内容を弊社までご連絡ください。

Name = <u>OriginalDB</u> Family = C:/INETPUB/MASCOT/sequence/OriginalDB/current/OriginalDB_*.fasta Filename = <u>Halted</u>: First test failed <u>check error log</u> Ty-ault and <u>retry</u> State Time = Hunders to mem map = YES Request unmap = NO Mem locked = NO Number of threads = 4 Current = NO



2.オリジナルデータベースの更新

オリジナルデータベースの内容を変更したい場合は、

C:¥inetpub¥mascot¥sequence¥(DB名)¥current

にあるデータベースファイルのうち、拡張子が.fasta のファイル(最初に作成したファイ

ル)をテキストエディタで開き、その内容を書き換えて保存してください。

保存後、MASCOT が自動的に認識し、検索用 DB を作成し直します。作成のやり直しには 1 分ほど時間がかかります。

以上です。ご不明な点がございましたら下記問い合わせ先までご連絡ください。

<問い合わせ先>

技術サポート

電子メール	: support-jp@matrixscience.com				
電話	: 03-5807-7897				
ファックス	: 03-5807-7896				