

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

دانشکده‌ی ریاضی، آمار و علوم کامپیوتر

دانشگاه تهران

تهران

# پیشگویی ساختار سوم پروتئین‌ها بر اساس مدل آب‌گریز-آب‌دوست با استفاده از شبکه‌های عصبی

نگارش

صغری میکائیل‌نژاد

استاد راهنما

دکتر عباس نوذری دالینی

استاد مشاور

دکتر هایده اهرابیان

پایان‌نامه جهت دریافت درجه‌ی کارشناسی ارشد

در علوم کامپیوتر

بهمن ۸۷

University of Tehran  
College of Science  
School of Mathematics, Statistics and Computer Science

# **Prediction of Tertiary Structure of Proteins in the HP Model Using Neural Networks**

by

**Soghra Mikaeyl Nejad**

Under supervision of

Dr. Abbas Nowzari Dalini

Co-supervisor

Dr. Hayedeh Ahrabian

A thesis submitted to the Graduate Studies Office  
In partial fulfillment of the requirements for  
The degree of Master of Science

**Computer Science**

January 2009

## تقدیر و تشکر

وَسَخَّرَ لَكُمْ مَّا فِي السَّمَاوَاتِ وَمَا فِي الْأَرْضِ جَمِيعًا مِّنْهُ إِنَّ فِي ذَلِكَ لَآيَاتٍ لِّقَوْمٍ يَتَفَكَّرُونَ

حمد و سپاس فراوان خدای را که توفیق کسب علم و دانش نصیب بنده خویش نمود تا وجودش را به زینت علم بیاراید. اکنون که با لطف و استعانت پروردگار گامی دیگر را در زندگی خود پشت سر نهاده‌ام، بر خود لازم می‌دانم که مراتب سپاس و قدردانی خویش را تقدیم به کسانی کنم که در طول مدت تحصیل مرا یاری نموده‌اند.

با تشکر از اساتید محترم، آقای دکتر نوذری دالینی و خانم دکتر هایدی اهرابیان به خاطر راهنمایی‌هایشان در این پایان‌نامه که مطمئناً بدون هدایت ایشان این کار به انجام نمی‌رسید.

از پدر و مادر عزیزم که در تمام مراحل زندگی یاور و پشتیبان من بوده و همواره مرا مرهون لطف و محبت‌های خود نموده‌اند سپاس‌گزاری می‌کنم.

هم‌چنین از همکاری و کمک‌های دوستان عزیزم در گردآوری و ویرایش پایان‌نامه صمیمانه تشکر می‌کنم.

که دراز است ره مقصد و من نوسفرم

همت‌م بدرقه راه کن ای طایر قدس

## **تقدیم به**

دو ستاره همیشه درخشان زندگی‌م، پدر و مادر عزیز و مهربانم  
به پاس تمامی فداکاری‌ها، محبت‌ها، مهربانی‌ها، حمایت‌ها، تشویق‌ها و امیدهایی که همواره قدم‌هایم  
را در پیمودن مراحل مختلف زندگی استوارتر می‌کرد.

## **و تقدیم به**

برادر و خواهرانم  
که آسمان نگاه پرمهرشان شوق پیمودن این راه را در من زنده می‌کرد.

## چکیده

با توجه به نقش و کارکرد حیاتی پروتئین‌ها در بدن انسان و وابستگی عمل کرد یک پروتئین به ساختار سه‌بعدی آن پیش‌بینی ساختار توالی پروتئین اهمیت فوق‌العاده‌ای می‌یابد. تاکنون روش‌های مختلفی برای این مسئله ارائه شده است. در برخی از این روش‌ها از شبکه‌های عصبی برای پیش‌گوئی ساختار پروتئین‌ها استفاده شده است که در عمل به نتایج قابل قبولی منجر شده‌اند. یکی از این روش‌ها استفاده از یک شبکه عصبی به نام شبکه کشسان است. همچنین در برخی از این الگوریتم‌ها از خاصیت آب‌دوستی و آب‌گریزی اسیدهای آمینه پروتئین‌ها برای حل مسئله پیش‌گوئی ساختار پروتئین‌ها استفاده می‌کنند. در این پایان‌نامه پس از معرفی مقدمات زیست‌شناسی مولکولی و شبکه‌های عصبی، الگوریتم‌هایی که برای تا کردن پروتئین‌ها با استفاده از شبکه کشسان وجود دارند بررسی می‌شوند. در این الگوریتم‌ها یک توالی پروتئین به عنوان ورودی به شبکه کشسان داده می‌شود. خروجی شبکه بهترین تا خوردگی برای توالی می‌باشد. در نهایت یک شبکه کشسان با معیار جدیدی برای انرژی شبکه با استفاده از سطح دسترسی اسیدهای آمینه توالی ارائه خواهد شد.

## پیش گفتار

یکی از اجزای مهم و اساسی در سلول‌های موجودات زنده پروتئین‌ها هستند که انواع مختلفی دارند. هر یک از این انواع پروتئین‌ها فعالیت مخصوص به خود دارند و فعالیت‌های ضروری موجودات زنده را کنترل می‌کنند. پروتئین‌ها از مولکول‌های پلیمر ناهمگن که از زیر واحدهایی که در یک رشته خطی به هم وصل شده‌اند، تشکیل یافته‌اند. زیرواحدهای تشکیل دهنده پروتئین‌ها اسیدهای آمینه می‌باشند و در کل ۲۰ نوع اسید آمینه در طبیعت وجود دارد. چگونگی تا خوردن رشته پروتئین و نحوه قرار گرفتن این زیرواحدها، به روش‌های مختلفی انجام می‌گیرد که فقط یکی از این تا خوردگی‌ها باعث می‌شود پروتئین فعالیت اصلی خود را به درستی انجام دهد و در پایین‌ترین سطح انرژی قرار بگیرد. نحوه تا خوردگی یک پروتئین به پیش‌گوئی تا خوردگی پروتئین یا پیش‌گوئی ساختار پروتئین معروف است. بیماری‌هایی مانند آلزایمر، جنون گاوی و حتی برخی از سرطان‌ها از تا شدن نادرست برخی از پروتئین‌ها ناشی می‌شوند. اگر پروتئینی به طرز ناصحیحی تا بخورد برای سلول‌های مجاور نیز ایجاد مسمومیت می‌کند. اگر یک پروتئین تا خورده باز شود، دوباره به همان حالت اصلی خود تا می‌خورد. تشخیص نحوه تا خوردن یک پروتئین به پیش‌گوئی تا خوردن پروتئین یا پیش‌گوئی ساختار پروتئین معروف است. تاکنون رویکردهای مختلفی برای پیش‌گوئی تا خوردن پروتئین‌ها ارائه شده است. در این روش‌ها به طور کلی دنباله‌ای از اسیدآمینه‌ها به عنوان ورودی دریافت می‌شود و الگوریتم سعی می‌کند بهترین روش تا خوردن آن را که به ساختار اصلی این پروتئین نزدیک‌تر است به عنوان خروجی تولید کند. یکی از عواملی که در چگونگی تا خوردن پروتئین‌ها اثر می‌گذارد، ویژگی‌های اسیدآمینه‌های موجود در توالی است. اسیدآمینه‌های موجود در رشته پروتئین دارای خاصیت آب‌گریزی یا آب‌دوستی هستند. اسیدآمینه‌های آب‌دوست برخلاف اسیدآمینه‌های آب‌گریز تمایل زیادی به تماس با مولکول‌های آب

دارند، از این رو به هنگام تاخوردن پروتئین اسیدآمین‌های آب‌دوست تمایل دارند که به سمت بیرونی ساختار رفته و نزدیک به مولکول‌های آب قرار بگیرند. اسیدآمین‌های آب‌گریز نیز در مرکز ساختار یک هسته آب‌گریز تشکیل می‌دهند.

ویژگی دیگری که اسیدآمین‌ها دارند سطح دسترسی آن‌هاست. منظور از سطح دسترسی یک اسیدآمین، نسبت مساحتی از آن که در محیط آبی با آب در تماس است به کل مساحت سطح آن اسیدآمین می‌باشد. سطح دسترسی اسیدآمین‌ها نیز نقش مهمی در پیش‌گویی ساختار پروتئین‌ها دارد. در سال‌های اخیر از تکنیک‌های ماشین یادگیری از قبیل شبکه‌های عصبی به طور گسترده‌ای در روش‌های پیش‌گویی ساختار پروتئین‌ها استفاده می‌شود. در این روش‌ها توالی پروتئین به عنوان ورودی به شبکه وارد می‌شود و شبکه بهترین تاخوردگی آن را با کم‌ترین سطح انرژی به عنوان خروجی تولید می‌کند. یکی از شبکه‌های عصبی که در این زمینه به کار گرفته شده است، شبکه کشسان نام دارد. این شبکه که بیشتر جنبه هندسی دارد اغلب برای مسائل بهینه‌سازی استفاده می‌شود. شبکه‌های کشسانی که تاکنون برای حل مسئله تاکردن پروتئین‌ها استفاده شده‌اند یک رشته پروتئین را با استفاده از خاصیت آب‌گریز-آب‌دوستی اسیدآمین‌های آن بر روی یک لاتیس تا می‌کنند. انرژی ساختار پروتئین در این روش‌ها بر حسب این که هر جفت اسیدآمین آب‌گریزی که بر روی لاتیس مجاور باشند و در توالی هم‌جوار نباشند محاسبه می‌شود.

در این پایان‌نامه راه‌حل‌های بهینه برای مسئله تاکردن پروتئین‌ها با استفاده از شبکه عصبی کشسان بررسی شده‌اند به طوری که یک رشته پروتئین به عنوان ورودی به شبکه وارد می‌شود و این شبکه بهترین تاخوردگی آن را با کمترین سطح انرژی به عنوان خروجی تولید می‌کند. در روش‌هایی که بحث شده‌اند از مدل آب‌گریز-آب‌دوست استفاده شده است. در انتها روشی نوین با استفاده از سطح دسترسی هر اسیدآمین در یک رشته پروتئین پیشنهاد شده است.

در فصل اول به تعریف مفاهیم اولیه زیستی و معرفی شبکه‌های عصبی پرداخته می‌شود. سپس در فصل دوم شبکه کشسان معرفی شده و نحوه عمل‌کرد آن توضیح داده می‌شود. فصل سوم شامل الگوریتم‌های شبکه کشسان دوبعدی و سه‌بعدی موجود برای تاکردن پروتئین‌هاست و در فصل آخر مشکلات روش‌های قبلی بررسی شده و راه‌حلی برای رفع این مشکلات ارائه شده است. همچنین



یک الگوریتم شبکه کشسان با معیاری جدید به نام سطح دسترسی برای تعیین سطح انرژی ساختار ارائه خواهد شد.

# فهرست مطالب

۱	مفاهیم اولیه	۱
۱	مفاهیم زیستی	۱-۱
۱	اسیدهای نوکلئیک	۱-۱-۱
۵	پروتئین‌ها	۲-۱-۱
۱۴	پروتئومیکس	۳-۱-۱
۱۶	تا کردن پروتئین‌ها	۴-۱-۱
۱۸	مدل آب‌گریز آب‌دوست	۵-۱-۱
۲۰	شبکه‌های عصبی	۲-۱
۲۰	مدل محاسباتی شبکه‌های عصبی	۱-۲-۱
۲۴	شبکه عصبی هاپفیلد	۲-۲-۱
۲۷	روش شبیه‌سازی تبرید	۳-۱
۳۲	شبکه کشسان	۲
۳۲	معرفی شبکه	۱-۲
۳۳	پیکربندی شبکه	۲-۲
۳۶	بررسی انرژی شبکه کشسان	۳-۲
۳۸	آرایش فضای اولیه شبکه کشسان و بسط آن	۴-۲
۳۹	الگوریتم شبکه کشسان برای مسئله فروشنده دوره‌گرد	۵-۲

۴۳	تاکردن پروتئین‌ها با روش شبکه کشسان	۳
۴۳	معرفی روش	۱-۳
۴۵	ساختار کلی شبکه	۲-۳
۴۹	تاکردن پروتئین‌ها در حالت دوبعدی	۳-۳
۵۰	جستجوی محلی	۴-۳
۵۳	تاکردن پروتئین‌ها در حالت سه بعدی	۵-۳
۵۵	جستجوی محلی LS1	۶-۳
۵۹	جستجوی محلی LS2	۷-۳
۶۳	پیش‌گویی تاکردن پروتئین‌ها با سطح دسترسی	۴
۶۳	مشکلات روش‌های قبلی	۱-۴
۶۶	تابع انرژی با استفاده از سطح دسترسی	۲-۴
۶۷	الگوریتم ارائه شده برای تاکردن پروتئین‌ها در حالت سه‌بعدی	۳-۴
۶۹	پیاده‌سازی و نتایج	۴-۴
۷۲	پیشنهادات	۵-۴
۷۳	مراجع	
۷۸	واژه‌نامه‌ی فارسی	
۸۳	واژه‌نامه‌ی انگلیسی	

## فصل ۱

# مفاهیم اولیه

در این فصل مفاهیم مقدماتی که برای پایان نامه لازم است بیان می‌شود. در این قسمت ابتدا به بررسی پروتئین‌ها پرداخته می‌شود [۷، ۳۸] و در ادامه شبکه‌های عصبی مورد مطالعه قرار می‌گیرند [۹].


### ۱-۱ مفاهیم زیستی

زیست‌شناسی یا به عبارت دیگر علوم زیستی همواره در پی شناخت بیشتر و بهتر ساختار موجودات زنده و ارتباط آن‌ها با یکدیگر می‌باشد. ساختار موجودات زنده از اجزا متنوعی تشکیل شده است که در این بخش مواردی از آن‌ها که در این پایان‌نامه مورد نیاز است تعریف می‌گردد.

#### ۱-۱-۱ اسیدهای نوکلئیک

در هسته هر سلول مولکول‌هایی قرار دارند که اساسی‌ترین اطلاعات حیات را در خود ذخیره کرده‌اند. این مولکول‌ها، داکسی ریبونوکلئیک‌اسید نام دارند. داکسی ریبونوکلئیک‌اسیدها از چهار نوع مولکول ساخته شده‌اند که به آن‌ها نوکلئوتید گفته می‌شود. این چهار نوکلئوتید آدنین، گوانین، سیتوزین و تیمین نام دارند. در شکل ۱-۱ این نوکلئوتیدها نشان داده شده‌اند. این مولکول‌ها خود به دو زیر گروه تقسیم می‌شوند: آدنین و گوانین در گروه پیورین قرار می‌گیرند و سیتوزین و تیمین در گروه پیریمیدین جای داده می‌شوند.

هنگام سنتز مولکول *DNA*، نوکلئوتیدها به اسیدهای نوکلئیک تبدیل می‌شوند که با پیوند فسفودی‌استر آن‌ها به یکدیگر، رشته‌های *DNA* ساخته می‌شوند. *DNA* یک مارپیچ دوتایی است، این مارپیچ در شکل




شکل ۱-۱ : ساختار نوکلئوتیدهای رشته DNA.

۱-۲ نشان داده شده است. نوکلئوتیدها حلقه‌های مسطحی دارند که اندازه آن‌ها بین ۳ تا ۴ آنگستروم می‌باشد. وقتی مارپیچ دوتایی تشکیل می‌شود، مولکول‌های *A* با مولکول‌های *T* رشته مقابل و مولکول‌های *G* با مولکول‌های *C* رشته روبه‌رو پیوند هیدروژنی برقرار می‌کنند و جفت‌های قلیایی ایجاد می‌شود. این جفت‌های قلیایی باعث می‌شوند که مارپیچ پایدار باقی بماند. تصاویری که با استفاده از اشعه *X* از مولکول *DNA* گرفته شده است، نشان می‌دهد که در هر دور از مارپیچ ۱۰ جفت قلیایی وجود دارد. ساختمان سه‌بعدی *DNA* در سال ۱۹۵۳، تقریباً ۲۰ سال پس از کشف ماهیت شیمیایی *DNA* به‌وسیله جمیز واتسون<sup>۱</sup> و فرانسیس کریک<sup>۲</sup> کشف شد. مدل مارپیچی می‌تواند نحوه رونویسی از مولکول *DNA* در هنگام تقسیم سلول را نیز توجیه کند. در هنگام تقسیم سلول، باید نسخه مشابهی از *DNA* تهیه شود تا در سلول‌های جدید قرار گیرد. این فرآیند اصطلاحاً رونویسی نامیده می‌شود. برای انجام این کار، اتصالات هیدروژنی بین نوکلئوتیدها باز شده و دو رشته مارپیچ از هم جدا می‌گردند. سپس هر یک از این رشته‌ها به عنوان پایه‌ای برای ساخت رشته مقابل استفاده می‌شوند. به این ترتیب دو مارپیچ کاملاً یکسان *DNA* ساخته می‌شوند و هر کدام از آن‌ها در یکی از دو سلول نوزاد قرار می‌گیرد. چون در هر بار رونویسی، نیمی از مولکول *DNA* قبلی حفظ می‌شود، گفته می‌شود که رونویسی *DNA*، نیمه

<sup>۱</sup> James Watson

<sup>۲</sup> Francis Crick



شکل ۱-۲: مارپیچ رشته DNA.

پایستار است. اگرچه DNA اطلاعات ژنتیکی جاندار زنده را در خود دارد، اما برای عمل کرد موفق به وجود ریبونوکلیک اسید یا RNA نیاز دارد. RNA هم مانند DNA از رشته‌های اسید نوکلئیکی تشکیل شده که با پیوندهای مشابهی به هم متصل شده اند، اما دو تفاوت عمده با DNA دارد. اول اینکه در ساختار آن به جای تیمین، از اوراسیل<sup>۳</sup> استفاده شده است و دوم اینکه مارپیچی نیست و فقط از یک رشته تنها ساخته شده است. برای انجام بعضی کارها RNA از روی DNA ساخته می‌شود. ساخته شدن RNA از روی DNA را رونویسی می‌گویند. رونویسی به وسیله آنزیم RNA پلی‌مراز صورت می‌گیرد. رونویسی براساس وجود رابطه مکملی بین بازها انجام می‌شود. در شکل ۱-۳ نمونه‌ای از رونویسی RNA از روی DNA دیده می‌شود. اساس رونویسی در پروکاریوت‌ها و یوکاریوت‌ها یکسان است. در این جا ابتدا رونویسی در پروکاریوت‌ها بررسی می‌شود. رونویسی در سه مرحله انجام می‌شود.

مرحله اول: آغاز


مرحله دوم: ادامه

مرحله سوم: پایان

مرحله اول رونویسی با اتصال آنزیم RNA پلی‌مراز به قسمتی از DNA به نام راه‌انداز آغاز می‌شود. راه‌انداز قسمتی از DNA است که به آنزیم امکان می‌دهد رونویسی را از محل درست آغاز کند و این کار را مثلا از وسط ژن آغاز نکند. اگر RNA پلی‌مراز روی قسمتی از DNA بنشیند که آن جا راه‌انداز نباشد، آن قدر روی DNA حرکت می‌کند تا به راه‌انداز برسد.

---

<sup>۳</sup> Uracil



شکل ۱-۳: رونویسی RNA از روی رشته DNA

در مرحله دوم RNA پلی‌مراز دو رشته‌ای DNA را از یکدیگر باز می‌کند و یکی از دو رشته DNA را رونویسی می‌کند. به این ترتیب که در مقابل هریک از رئوکسی ریبونوکلئوتیدهای آن، ریبونوکلئوتید مکمل را قرار می‌دهد و هر ریبونوکلئوتید را به ریبونوکلئوتید قبلی وصل می‌کند. اولین نوکلئوتیدی از DNA را که رونویسی می‌شود جایگاه رونویسی می‌نامند.

در انتهای ژن، قسمت مخصوصی وجود دارد که به آن جایگاه پایان رونویسی می‌گویند، با رونویسی شدن این جایگاه DNA، mRNA و آنزیم RNA پلی‌مراز از یکدیگر جدا می‌شوند و رونویسی پایان می‌پذیرد. نحوه عمل آنزیم RNA پلی‌مراز در کلیه مراحل رونویسی بدون درنگ به دنبال هم اجرا می‌شوند. RNAهایی که در حال ساخته شدن هستند ساختارهای پرمانندی را به نمایش می‌گذارند. علت ایجاد چنین ساختاری این است که به محض ترک راه انداز توسط RNA پلی‌مراز، آنزیم دیگری می‌تواند روی آن بنشیند و رونویسی را آغاز کند. بنابراین در حالی که آنزیم اول قدری از رونویسی را به پیش برده است آنزیم دوم تازه رونویسی را آغاز کرده است. در نتیجه طول RNAی که آنزیم دوم ساخته است از طول RNAی که آنزیم اول ساخته است کوتاه‌تر است. این روند هم‌چنان ادامه پیدا می‌کند. به این معنی که وقتی آنزیم دوم راه انداز را ترک کرد آنزیم سوم روی راه‌انداز می‌نشیند و RNAی که می‌سازد از RNAی

که آنزیم دوم در حال ساختن آن است کوتاه‌تر است.

به‌طور کلی دستگاه رونویسی یوکاریوتی پیچیده‌تر از دستگاه پروکاریوتی است سلول‌های یوکاریوتی برخلاف سلول‌های پروکاریوتی که تنها یک نوع آنزیم *RNA* پلی‌مراز دارند دارای سه نوع آنزیم‌اند. تفاوت دیگری که رونویسی در یوکاریوت‌ها با رونویسی در پروکاریوت‌ها دارد این است که در یوکاریوت‌ها آنزیم *RNA* پلی‌مراز قادر نیست به تنهایی راه‌انداز را شناسایی کند. اتصال آنزیم به راه‌انداز به کمک پروتئین‌های ویژه‌ای به نام عوامل رونویسی صورت می‌گیرد. همچنین در یوکاریوت‌ها *RNA* قبل از خروج از هسته دست‌خوش تغییر می‌شود و به *RNA* بالغ تبدیل می‌گردد.

## ۲-۱-۱ پروتئین‌ها


تمام فعالیت‌هایی که در یک سلول انجام می‌شود بر عهده پروتئین‌ها است. تقریباً همه پروتئین‌ها اثر خود را با همکاری پروتئین‌های دیگر در سلول اعمال می‌کنند و هیچ پروتئینی نیست که در سلول به تنهایی عمل کند. اصلی‌ترین مواد مغذی هر سلول زنده پروتئین‌ها هستند. در ساختمان آن‌ها نه تنها کربن، هیدروژن و اکسیژن وجود دارد، بلکه ازت و گاهی گوگرد نیز در بعضی ترکیبات آن‌ها دیده می‌شود. پروتئین‌ها مسئول انجام اعمال گوناگونی هستند. آن‌ها در تشکیل ماده انقباضی عضلات نقش مهمی ایفاء می‌کنند و همچنین در ساختن بعضی از هورمون‌ها، آنزیم‌ها و آنتی‌کورها و تبدیل انرژی شیمیایی به کار به‌طور گسترده استفاده می‌شوند. یکی از مسائل مهمی که موجب ایجاد انگیزه برای شناخت پروتئین‌ها در دانشمندان می‌شود، تولید دارو است. در صورتی که به درستی ساختار عوامل حمله‌کننده شناسایی شوند و چنان‌چه ساختاری متناسب با عامل مورد نظر پیدا کرده و تولید شود، با بسیاری از بیماری‌ها به سادگی می‌توان مبارزه کرد. این امر بسیاری از شرکت‌های داروسازی را بر آن داشته است که به طراحی پروتئین‌ها به عنوان دارو بپردازند. پروتئین‌ها از زیرواحدهایی به نام اسیدآمینه ساخته شده‌اند و همان‌طور که قبلاً اشاره شد در فرآیند رونویسی و ترجمه از روی مولکول‌های *DNA* موجود در هسته به وجود می‌آیند. از آن‌جا که اسیدهای آمینه با ترتیب‌های مختلف و با طول نامحدود در یک توالی می‌توانند قرار بگیرند، از این‌رو انواع بی‌شماری از پروتئین‌ها می‌توانند وجود داشته باشند. هر موجود زنده توانایی ساخت تعداد زیادی پروتئین را دارد. به عنوان مثال، هر انسان بین ۳۰۰۰۰ تا ۵۰۰۰۰ پروتئین



مختلف می‌سازد.

به صورت کلی پروتئین از تعدادی اسید آمینه تشکیل شده است که در یک رشته پشت‌سر یکدیگر قرار گرفته‌اند. ترتیب و ماهیت اسیدهای آمینه، ویژگی‌های هر پروتئین را تعیین می‌کند. یک پروتئین با طول متوسط حدود ۱۰۰ اسید آمینه دارد. تعداد کل اسید آمینه‌های موجود در طبیعت ۲۰ عدد می‌باشد که هر کدام از ترکیب‌های متفاوتی از اتم‌های پیوند خورده به وجود آمده‌اند و با توجه به ترکیب و ترتیب اتم‌ها، هر اسید آمینه خواص خاص خود را داراست. به رشته اسید آمینه که پروتئین از آن تشکیل شده ساختار اول یا توالی پروتئین می‌گویند. تمامی اسیدهای آمینه دارای یک قسمت شبیه به هم هستند که این قسمت‌های شبیه، به یکدیگر متصل شده و ستون فقرات پروتئین را می‌سازند. تفاوت اسیدهای آمینه در باقی قسمت‌های آن‌هاست که به آن زنجیر جانبی می‌گویند. هر اسید آمینه، از یک کربن نامتقارن به نام کربن آلفا تشکیل شده که با چهار گروه مختلف کربوکسیل، اتم هیدروژن، گروه آمینه بازی و یک زنجیره غیر جانبی پیوند برقرار می‌کند. شکل ۱-۴ ساختمان مولکولی برخی از اسیدهای آمینه را به تصویر می‌کشد. زنجیره غیرجانبی یا گروه  $R$  ممکن است یک زنجیره کربنی و یا یک حلقه کربنی باشد. عوامل دیگری مانند الکل، آمین، کربوکسیل و نیز گوگرد می‌توانند در ساختمان ریشه  $R$  شرکت کنند. این زنجیره جانبی خود چندین اتم کربن دارد و آن‌ها را به ترتیبی که از کربن آلفا فاصله می‌گیرند، با حروف بتا  $\beta$ ، گاما  $\gamma$  و دلتا  $\delta$  نشان می‌دهند. اگر در حالی که عامل کربوکسیل روی کربن آلفا قرار دارد، گروه آمینه روی کربن‌های غیرآلفا قرار گیرد، نوع اسید آمینه به  $\beta$  یا  $\delta$  تغییر خواهد کرد. اسیدهای آمینه آزاد، به مقدار بسیار ناچیز در سلول‌ها وجود دارند. بیشتر اسیدهای آمینه آلفا در سنتز پروتئین می‌کنند، در صورتی که اسیدهای آمینه بتا، گاما و دلتا واسطه‌های شیمیایی هستند.

هر یک از اسیدهای آمینه علاوه بر نام، دارای یک کد سه حرفی، یک کد یک حرفی و یک کد عددی هستند. نام این اسیدها و کدهای آن‌ها در شکل ۱-۵ نشان داده شده است. کدهای سه حرفی در حقیقت توالی سه نوکلئوتیدی است که این اسیدآمینه را کد می‌کند و در فرآیند ساخت اسیدآمینه، این توالی نوکلئوتیدی باعث تولید اسیدآمینه متناظر می‌شود. اسیدهای آمینه در آغاز تشکیل زمین، به همراه سایر مواد آلی پیدا شدند. اسیدهای آمینه‌ای که در حضور پرتوهای فرابنفش بوجود آمدند،



شکل ۱-۴: ساختمان مولکولی اسیدهای آمینه.

Name	Integer	Code	Abberviation	codons
Alanine	1	A	Ala	GCU GCC GCA GCG
Arginine	2	R	Arg	CGU CGC CGA CGG AGA AGG
Asparagine	3	N	Asn	AAU AAC
Aspartic acid (Aspartate)	4	D	Asp	GAU GAC
Cysteine	5	C	Cys	UGU UGC
Glutamine	6	Q	Gln	CAA CAG
Glutamic acid (Glutamate)	7	E	Glu	GAA GAG
Glycine	8	G	Gly	GGU GGC GGA GGG
Histidine	9	H	His	CAU CAC
Isoleucine	10	I	Ile	AUU AUC AUA
Leucine	11	L	Leu	UUA UUG CUU CUC CUA CUG
Lysine	12	K	Lys	AAA AAG
Methiomine	13	M	Met	AUG
Phenylalamine	14	F	Phe	UUU UUC
Proline	15	P	Pro	CCU CCC CCA CCG
Serine	16	S	Ser	UCU UCC UCA UCG AGU AGC
Threonine	17	T	Thr	ACU ACC ACA ACG
Tryptophan	18	W	Trp	UGG
Tyrosine	19	Y	Tyr	UAU UAC
Valine	20	V	Val	GUU GUC GUA GUG

شکل ۱-۵: لیست کدهای داده شده اسیدهای آمینه.

گوناگونی بسیار داشته‌اند، اما به دلایلی ناشناخته، تنها بیست اسید آمینه در سلول زنده کاربرد پیدا کرده‌اند. تمام پروتئین‌ها از همین بیست اسید آمینه تشکیل شده‌اند. در شکل ۵-۱ ساختمان مولکولی این اسید آمینه‌ها نشان داده شده است. در ادامه چگونگی سنتز پروتئین‌ها بررسی می‌شود.

پروتئین‌ها از اتصال اسیدهای آمینه به یکدیگر از طریق پیوند پپتیدی بدست می‌آیند. تشکیل پیوند پپتیدی و قرار گرفتن ترتیب اسیدهای آمینه که برای هر پروتئین اختصاصی است، به سادگی امکان پذیر نیست. به همین دلیل می‌بایست در سلول مکانیسم ویژه‌ای وجود داشته باشد که بتواند ویژگی پروتئین‌ها را حفظ کند. بیوسنتز پروتئین‌ها در واقع ترجمه ترتیب نوکلئوتیدهای *DNA* به مولکول پروتئین بوسیله *RNA* است. انتقال اطلاعات از *DNA* به وسیله *mRNA* امکان پذیر است. بدین ترتیب برای هر پروتئین، *mRNA* اختصاصی آن پروتئین وجود دارد. به عبارت دیگر هر پروتئین در روی *DNA*، ژن اختصاصی دارد که اطلاعات آن ژن در *mRNA* رونویسی و در مولکول ترجمه می‌شود. در بیوسنتز پروتئین‌هایی که در ساختارشان بیش از چند اسید آمینه دارند، وجود یک مکانیسم سنتزی که در آن ترکیبات و عوامل بسیاری دخالت می‌کنند، الزامی است. این مکانیسم به یک سیستم رمزیاب نیاز دارد که بطور خودکار واحد اسید آمینه معینی را در موقعیت ویژه‌ای از زنجیره پروتئینی قرار می‌دهد. در ادامه ترکیباتی که در سنتز پروتئین شرکت می‌کنند شرح داده می‌شود.

*mRNA*: این *RNA* اطلاعات مربوط به پروتئین ویژه‌ای را از مولکول *DNA* می‌گیرد و به ماشین سنتز کننده پروتئین یا ریبوزوم انتقال می‌دهد. در ترتیب نوکلئوتیدهای *mRNA* هر سه نوکلئوتید مجاور بیان گر رمز یا کدون یک اسید آمینه مشخص هستند و به همین جهت ترتیب نوکلئوتیدها در *mRNA* بیان کننده ترتیب اسیدهای آمینه در پروتئین است. هر اسید آمینه رمز مشخصی دارد. فقط متیونین و تریپتوفان یک رمز دارند، در حالی که سایر اسیدهای آمینه واجد دو یا تعداد بیشتری رمز هستند. رمز میتونین همواره *AUG* است که آغاز سنتز را در همه پروتئین‌ها به عهده دارد. در سلول‌های پروکاریوت و یوکاریوت، پروتئین سازی با میتونین آغاز می‌شود. سه رمز *UGA* و *UAA* و *UAG* برای پروتئین رمزخوانی نمی‌کنند، بلکه رمزهایی هستند که پایان سنتز زنجیره پروتئین را بیان می‌کنند.

*tRNA*: ساختار سه بعدی *L* شکل دارد که در آن دو ناحیه پذیرنده و آنتی کدون آزادند و بقیه مولکول تاب خورده است. آنتی کدون یا پادرمز شامل سه نوکلئوتید است که مکمل رمز ویژه‌ای از