

HIERARCHICAL TEMPORAL MEMORY: NEW APPROACH IN PATTERN RECOGNITION

Ch. Kenshimov, D. Yedilkhan

Institute of Informational and Computing Technologies of the MES RK, Almaty, Kazakhstan.
E-mail: kenshimov.chingiz@gmail.com; yedilkhan@gmail.com

Keywords: pattern recognition, HTM, neural network.

Abstract. In this work, we consider a new technology of pattern recognition that is based on the hierarchical temporal memory. Hierarchical temporal memory (HTM) is a technology that replicates structural and algorithmic properties of a neocortex, which is a major part of a human brain. The technology is applied for the recognition and modeling of cognitive tasks on hierarchical structures of memory. Because of this, hierarchical temporal memory gives opportunity to create machines that are capable to reach and exceed human level when performing cognitive tasks.

Hierarchical temporal memory can be considered as one of neural network types. By definition, any system, which tries to model architectural details of a neocortex, is a neural network. However, hierarchical temporal memory models neurons (so-called cells in the context of HTM) which are located hierarchically in regions, columns and layers. In fact, HTM is a new form of a neural network.

HTM is organized as a hierarchical tree of nodes, where each node does the general task of training and storing. HTM stores information along the whole hierarchy. Thus, in this paper theory on which the HTM technology based is considered and basic functions are described in detail: "training", "recognition" and "prediction".

УДК 519.7

ИЕРАРХИЧЕСКАЯ ТЕМПОРАЛЬНАЯ ПАМЯТЬ: НОВЫЙ ПОДХОД В РАСПОЗНАВАНИИ ОБРАЗОВ

Ч. А. Кеншимов, Д. Едилхан

Институт информационных и вычислительных технологий МОН РК, Алматы, Казахстан

Ключевые слова: распознавание образов, HTM, нейронная сеть.

Аннотация. В работе рассматривается новая технология распознавания образов, основанная на использовании иерархической темпоральной памяти. Иерархическая темпоральная память (HTM) – это технология, которая при обработке информации реплицирует структурные и алгоритмические свойства неокортекса, части коры головного мозга. Именно поэтому иерархическая темпоральная память предоставляет возможность построения машин способных достичь и превзойти человеческие результаты при выполнении когнитивных задач.

Иерархическую темпоральную память можно рассматривать как один из типов нейронной сети. По определению, любая система, которая пытается моделировать архитектурные детали неокортекса является нейронной сетью. Особенность иерархической темпоральной памяти заключается в том, что она моделирует нейроны (так называемые клетки в контексте HTM), которые иерархически расположены в регионах столбцами и слоями. По сути HTM является новой формой нейронной сети.

HTM организована как древообразная иерархия узлов, где каждый узел выполняет общую задачу обучения и запоминания. HTM хранит информацию вдоль всей иерархии. Таким образом, в работе рассматривается теория, на которой основана технология HTM и описываются в деталях основные возможности решения интеллектуальных задач: «обучение», «распознавание» и «прогнозирование».

Введение. Существует множество повседневных операций, которые человек способен выполнять легко и точно, но на которые пока не способен компьютер. Такие задачи, как распознавание визуальных образов, понимание разговорной речи, распознавание и манипулирование объектами, и навигация в естественной среде, выполняются людьми легко. Однако после многих десятилетий исследований мы все также не имеем алгоритмов для выполнения этих и других когнитивных задач на компьютерах. Человеком эти задачи в основном выполняются неокортексом, частью коры головного мозга, которая занимает 96% площади. Иерархическая темпоральная память (НТМ – Hierarchical Temporal Memory) – это технология, которая реплицирует структурные и алгоритмические свойства неокортекса. Поэтому НТМ предоставляет возможность построения машин способных достичь и превзойти человеческие результаты при выполнении когнитивных задач [6, 9–11].

Иерархическая темпоральная память (НТМ) не похожа на традиционные программируемые компьютеры. С традиционными компьютерами программист создает конкретную программу для решения конкретной задачи. Например, одна программа может решать задачу распознавания речи и совсем другая программа может быть использована для прогноза погоды. НТМ, с другой стороны может быть понята как система памяти. НТМ не программируется и не исполняет различные алгоритмы для различных проблем. Вместо этого, НТМ «изучает» как решать проблемы. В НТМ подаются данные с сенсоров и ее возможности определяются тем, какими данными она снабжалась [1].

НТМ можно рассматривать как тип нейронной сети. По определению, любая система, которая пытается моделировать архитектурные детали неокортекса является нейронной сетью. Тем не менее, сам по себе, термин "нейронные сети" не очень удачен, потому что он применяется к большому числу систем. НТМ моделирует нейроны (так называемые клетки в контексте НТМ), которые расположены столбцами, слоями, в регионах и иерархично. Детали имеют значение, и по сути НТМ является новой формой нейронной сети.

НТМ организована как древообразная иерархия узлов, где каждый узел выполняет общую задачу обучения и запоминания. НТМ хранит информацию вдоль всей иерархии. Все объекты в мире, будь то машины, люди или здания, имеют иерархичную структуру в пространстве и во времени. НТМ память так же иерархична в пространстве и во времени, поэтому способна эффективно представлять структуру мира [1]. НТМ может быть реализована на обычных современных компьютерах, однако для понимания концепции лучше их рассматривать как систему памяти.

1. Основы НТМ. НТМ сеть состоит из регионов, расположенных в иерархии. Регион – основной блок памяти и прогнозирования в НТМ, и будет подробно рассмотрен в следующем разделе. Как правило, каждый регион НТМ представляет один уровень в иерархии. По мере подъема вверх по иерархии всегда наблюдается схождение – несколько элементов в дочернем регионе объединяются в один элемент в родительском регионе. Однако из-за наличия обратной связи, информация также расходится, по мере движения вниз по иерархии [2].




Рисунок 1 – Упрощенная диаграмма четырех НТМ регионов, расположенных в четырех уровнях иерархии

Преимущество иерархичной организации заключается в эффективности. Это значительно сокращает время обучения и объем памяти, потому что образы, извлеченные на каждом уровне иерархии, повторно используются при объединении в новом виде на более высоких уровнях. Для иллюстрации, давайте рассмотрим зрение. На самом низком уровне иерархии, ваш мозг хранит информацию о крошечных участках визуального поля, таких как края и углы. Эти образы нижнего

уровня объединяются на среднем уровне в более сложные компоненты, такие как кривые и текстуры. Дуга может быть краем уха, верхней частью рулевого колеса или ручкой чашки кофе. Эти образы среднего уровня, в свою очередь объединяются уровнем выше, для составления более глобальных признаков объектов, таких как голова, машина или чашка. Чтобы изучить новый объект высокого уровня вы, не должны заново изучать его компоненты.

Общие образы в иерархии также ведут к обобщению ожидаемого поведения. При виде нового животного, если вы замечаете рот и зубы, вы можете предсказать, что это животное ест ртом, и что оно может укусить вас. Иерархия позволяет новому объекту в мире, наследовать известные свойства его подкомпонентов.

1.1. Регионы. Понятие о регионах, соединенных в иерархии, исходит из биологии. Неокортекс – это большой лист нервной ткани, около 2 мм толщиной. Биологи делят неокортекс на различные области, прежде всего, в зависимости от того, как регионы соединяются друг с другом. Некоторые регионы получают вход непосредственно из органов чувств, а другие регионы получают на вход сигнал только после того, как он прошел через несколько других регионов. Это соединение регионов друг с другом определяет иерархию.

Все регионы коры мозга похожи в деталях. Они различаются по размеру и по расположению в иерархии, но в остальном они схожи. Если вы берете кусок региона в 2 мм толщиной коры головного мозга, то в разрезе вы увидите шесть слоев, пять слоев клеток и один не клеточный слой. Каждый слой в регионе неокортекса, состоит из множества взаимосвязанных клеток, расположенных в виде колонок. "Слой 3" в коре головного мозга является одним из основных слоев нейронов прямого распространения.




Рисунок 2 – Часть НТМ региона

НТМ регионы состоят из множества клеток. Клетки располагаются в виде двумерного массива колонок. На рисунке показана часть региона с четырьмя клетками в одной колонке. Несмотря на то, что НТМ регион эквивалентен только части кортикального региона, он способен делать выводы и прогнозировать на основе сложных потоков данных и, следовательно, может быть полезен во многих проблемах.

1.2. Редко распределённое представление. Хотя нейроны в коре головного мозга тесно взаимосвязаны, только небольшой процент нейронов активны в определенный момент времени. Таким образом, информация в мозге всегда представлена небольшим количеством активных нейронов из числа большой популяции нейронов. Такой вид кодирования называется «редко распределённым представлением» (англ. *Sparse Distributed Representation*). Любой активный нейрон несет в себе смысловую нагрузку, однако, интерпретирование значения должно идти в контексте всех активных нейронов, для получения полного смысла сигнала.

НТМ регионы также используют редко распределенное представление. На самом деле механизм работы НТМ зависит от такого представления, и не будет работать в противном случае. Входные данные не всегда могут быть редко распределёнными, поэтому первое, что область НТМ делает – это преобразовывает данные в нужный вид [7, 8].

Например, регион может принимать 20 000 бит информации, среди которых число активных бит («1») может варьироваться с течением времени. Иногда число активных может быть 5000, а

иногда 9000. НТМ регион может преобразовать эти данные во внутреннее представление, состоящее всегда из 10 000 бит и 2% (200 бит) из которых активны в определенный момент времени [3, 4].

Может казаться, что этот процесс может повлечь большие потери информации, так как число возможных шаблонов входных данных намного больше, чем количество возможных представлений в регионе. Тем не менее, оба числа невероятно велики. Количество фактических входных данных на самом деле составляет лишь малую часть всевозможных входов, и теоретический возможная потеря информации не будет иметь практического эффекта.




Рисунок 3 – НТМ регион с редко активированными клетками

1.3. Роль времени. Время играет важную роль в задачах обучения, вывода и предсказания.

Начнем с вывода. Без использования времени, нам сложно сделать какой-либо вывод из наших тактильных и слуховых ощущений. Например, с завязанными глазами вы можете определить предмет в вашей руке после его манипуляций всего за секунду или около того. Хотя и тактильная информация постоянно меняется, при перемещении пальцев по предмету, сам объект, а также ваш высокий уровень перцепции для этого объекта, - остается неизменным. Однако, если бы вам было запрещено двигать пальцами, то вы бы только строили догадки о строении предмета.

То же самое и справедливо для слуха. Статичный звук несет в себе мало информации. Любое слово, произнесенное человеком – это десятки или сотни быстрых, последовательных изменений звуковой волны во времени [5].

Касательно обучения, все системы НТМ должны подвергаться изменяющимся во времени входным данным во время тренировки. Даже в зрении, где статический вывод иногда возможен, мы должны видеть изменения изображения предметов, чтобы узнать, как выглядит объект. Например, представьте, что собака бежит в вашу сторону. В каждый определенный момент времени собака вызывает некую картину активности на сетчатке в глазу. Вы воспринимаете эти паттерны как различные изображения той же собаки, но математически модели полностью различны [12]. Мозг узнает, что эти различные модели означают одно и то же, наблюдая их в определенной последовательности. Время – это "супервайзер", который учит вас сопоставлять различные образы друг с другом [13–15].

Следует отметить, что входным данным недостаточно просто изменяться во времени. Последовательность не связанных между собой сенсорных образов приведет лишь к путанице. Все изменяющиеся во времени входы должны относиться к общему источнику. Отметим также, что, хотя и мы используем человеческие чувства в качестве примеров, общий случай относится и к нечеловеческим сенсорным данным. Например, если мы хотим тренировать НТМ для распознавания моделей изменения температуры, вибрации и шума датчиков электростанции, в НТМ нужно подавать меняющиеся во времени данные из этих датчиков [2].

Как правило, НТМ сеть должна быть обучена на большом количестве данных. Человек учится определять собак, видя множество примеров многих пород собак, а не только одного представителя одной породы собаки. Задача НТМ заключается в изучении последовательностей образов из входного потока данных, то есть построить модель, которая определяет какой образ следует за каким. Эта задача является трудной, потому что не всегда известно где начинается после-

довательность и где кончается; это могут быть перекрывающиеся последовательности. Кроме того, обучение должно происходить непрерывно и в присутствии шума.

2. Основные функции НТМ. Существует четыре основные функции НТМ: обучение, вывод, прогнозирование и поведение. В этом разделе мы опишем три первые из них. Поведение отличается от них. Из биологии нам известно, что основная часть неокортекса отвечает за поведение, однако эта функция не является основополагающей и многие интересные приложения возможно реализовать без этой функции.

2.1. Обучение. НТМ регион узнает об окружающем его мире, получая образы, и находя последовательности образов из сенсорных данных. Регион "не знает", что его входные данные представляют; он работает в чисто статистической манере. Он выискивает комбинации входных битов, которые встречаются вместе часто. Это мы называем пространственные образы. Затем регион ищет то, как эти пространственные образы появляются в последовательности во времени, что мы называем временные образы (паттерны) или последовательности [16].

Один НТМ регион имеет ограниченную способность к обучению. Регион автоматически регулирует возможности обучения в зависимости от того, сколько памяти она имеет и какая сложность у входных данных. Пространственные образы, изученные в регионе, становятся проще, если память, выделенная для региона, сокращается. И наоборот, пространственные структуры становятся более сложными, если выделенная память увеличивается. В случае если изученные пространственные образы в регионе простые, то для понимания сложных моделей необходима иерархия регионов. Мы наблюдаем такую структуру в системе человеческого зрения, где область неокортекса получающая входные данные от сетчатки различает пространственные образы мелких деталей визуального пространства [17, 18]. Только после того, как несколько уровней иерархии пространственных образов объединяются, полное представление визуального пространства становится доступным.

Алгоритмы обучения в регионе НТМ, как и в биологической системе, способны "онлайн обучению», то есть они непрерывно учатся от каждого нового входа. Здесь нет необходимости в отдельной стадии обучения, хотя естественно результаты вывода улучшаются после определенного времени обучения. По мере изменения входных образов, НТМ регион будет тоже соответственно меняться [6].

2.2. Вывод. После того, как НТМ регион узнал об образах в окружающем мире, он может выполнять вывод для новых входных данных. Когда НТМ получает новые данные, он сопоставляет их с ранее изученными пространственными и временными образами. Успешное соответствие новых данных ранее сохраненным последовательностям – это и есть суть вывода и поиска по шаблону [19, 20].

Для примера рассмотрим процесс узнавания мелодии. Первая нота в мелодии говорит вам немного. Вторая нота сужает варианты значительно, но этого все еще недостаточно. Обычно определение мелодии занимает три, четыре или более нот [5]. Вывод в регионе НТМ имеет схожий процесс. Регион постоянно анализирует поток входов и сопоставляет их с ранее изученными последовательностями. НТМ регион может найти соответствие в любом месте последовательности, аналогично тому, как вы можете узнать мелодию, начиная с любого места.

2.3. Прогнозирование. Каждый регион в НТМ хранит последовательности образов. Путем сопоставления ранее сохраненных последовательностей с текущим входом, регион формирует прогноз о том, какие данные последуют в будущем. НТМ регионы фактически хранят переходы между редко распределенными представлениями. В некоторых случаях эти переходы могут выглядеть как линейные последовательности, как в примере с нотами мелодии, но в общем случае, множество возможных будущих входов может быть предсказано в один момент времени. НТМ регион может дать разные прогнозы на основе контекста, которые могут растянуться далеко назад во времени. Большая часть памяти в НТМ предназначена последовательной памяти, то есть хранению переходов между пространственными образами [1].

Заключение. В данное время сделан значительный прогресс в преобразовании теоретической базы НТМ памяти в технологию с практическим применением. Было имплементировано и протестировано несколько версий алгоритмов кортикального обучения и было выявлено, что базовая архитектура построена правильно.

Данная технология, которая реплицирует лишь малую часть человеческого мозга, а именно третий слой региона неокортекса на практике имеет довольно широкое применение. Даже первая функция, которую мы описали, обучение и распознавание образов, потенциально имеет большие возможности применения на практике. Понимание высокоуровневых паттернов в биржевых колебаниях, выявление болезней, прогноз погоды, выгода в производстве или же выявление ошибок в комплексных системах, таких как энергосистема, вот малая часть возможных применений НТМ.

ЛИТЕРАТУРА

- [1] Hawkins, J., Blakeslee, S., *On Intelligence: How a New Understanding of the Brain will Lead to the Creation of Truly Intelligent Machines*. Henry Holt & Company, New York, NY, 2004.
- [2] Hawkins, J., George, D., *Hierarchical temporal memory: Concepts, theory and terminology*. Whitepaper, Numenta Inc., 2011.
- [3] Kostavelis, I., Gasteratos, A., *On the optimization of HierarchicalTemporal Memory*, Pattern Recognition Letters, Elsevier, 33, pp. 670-676, 2007.
- [4] Charalampous, K., Kostavelis, I., Amanatiadis, A. and Gasteratos, A., *A Sparse Deep-Learning Algorithm for Recognition and Categorisation*, Electronics Letters, Volume 48, Issue 20, pp. 1265–1266, 27 September 2012.
- [5] Numenta. *Problems that fit HTM*. Technical Report. Numenta, 2006
- [6] George, D., Hawkins, J., *Towards a mathematical theory of cortical microcircuits*. PLoS Comput. Biol. 5, 2009
- [7] Bundzel, M., Hashimoto, S., *Object identification in dynamic images based on the memory-prediction theory of brain function*. J. Intell. Learn. Syst. Appl. 2, 212–220, 2010.
- [8] Csapó, A., Baranyi, P., Tikk, D., *Object categorization using vfa-generated nodemaps and hierarchical temporal memories*. IEEE International Conference on Computational Cybernetics, ICC 2007. IEEE, pp. 257–262, 2007.
- [9] George, D., Jaros, B. *The htm learning algorithms*. Whitepaper, Numenta Inc, 2007.
- [10] Hawkins, J., George, D., *Hierarchical temporal memory: Concepts, theory and terminology*. Whitepaper, Numenta Inc., 2006.
- [11] Kapuscinski, T., *Using hierarchical temporal memory for vision-based hand shape recognition under large variations in hands rotation*. Artif. Intell. Soft Comput., 272–279, 2010.
- [12] Kjellström, H., Romero, J., Kragic, D., *Visual object-action recognition: Inferring object affordances from human demonstration*. Computer Vision and Image Understanding, 2010.
- [13] Melis, W., Kameyama, M., *A study of the different uses of colour channels for traffic sign recognition on hierarchical temporal memory*, in: Fourth International Conference on Innovative Computing, Information and Control (ICICIC), pp. 111–114, 2009.
- [14] Metta, G., Gasteratos, A., Sandini, G., *Learning to track colored objects with log-polar vision*. Mechatronics 14, 989–1006, 2004.
- [15] Mittal, A., Pagalthivarthi, K., *Temporal bayesian network based contextual framework for structured information mining*. Pattern Recognition Lett. 28, 1873–1884, 2007.
- [16] Rozado, D., Rodriguez, F., Varona, P., *Optimizing hierarchical temporal memory for multivariable time series*. In: Artificial Neural Networks – ICANN 2010. Springer, pp. 506–518, 2010.
- [17] Sandini, G., Tagliasco, V., *An anthropomorphic retina-like structure for scene analysis*. Comput. Graph. Image Process. 14, 365–372, 1980.
- [18] Stenger, B., Thayananthan, A., Torr, P., Cipolla, R., *Hand pose estimation using hierarchical detection*. In: Computer Vision in Human–Computer Interaction. Springer, pp. 105–116, 2004.
- [19] Qiao, L., Chen, S., Tan, X., *Sparsity Preserving Projections with Applications to Face Recognition*, Pattern Recognition, Elsevier, 43, pp. 331-341, 2010.
- [20] Martinez, T., Berkovich S., Schulten K., *"Neural-Gas" Network for Vector Quantization and its Application to Time-Series Prediction*, IEEE Trans. on Neural Networks, 4, pp. 558-569, 1993.

REFERENCES

- [1] Hawkins, J., Blakeslee, S., *On Intelligence: How a New Understanding of the Brain will Lead to the Creation of Truly Intelligent Machines*. Henry Holt & Company, New York, NY, 2004.
- [2] Hawkins, J., George, D., *Hierarchical temporal memory: Concepts, theory and terminology*. Whitepaper, Numenta Inc., 2011.
- [3] Kostavelis, I., Gasteratos, A., *On the optimization of HierarchicalTemporal Memory*, Pattern Recognition Letters, Elsevier, 33, pp. 670-676, 2007.
- [4] Charalampous, K., Kostavelis, I., Amanatiadis, A. and Gasteratos, A., *A Sparse Deep-Learning Algorithm for Recognition and Categorisation*, Electronics Letters, Volume 48, Issue 20, pp. 1265–1266, 27 September 2012.
- [5] Numenta. *Problems that fit HTM*. Technical Report. Numenta, 2006
- [6] George, D., Hawkins, J., *Towards a mathematical theory of cortical microcircuits*. PLoS Comput. Biol. 5, 2009
- [7] Bundzel, M., Hashimoto, S., *Object identification in dynamic images based on the memory-prediction theory of brain function*. J. Intell. Learn. Syst. Appl. 2, 212–220, 2010.
- [8] Csapó, A., Baranyi, P., Tikk, D., *Object categorization using vfa-generated nodemaps and hierarchical temporal memories*. IEEE International Conference on Computational Cybernetics, ICC 2007. IEEE, pp. 257–262, 2007.

- [9] George, D., Jaros, B. *The htm learning algorithms*. Whitepaper, Numenta Inc, 2007.
- [10] Hawkins, J., George, D., *Hierarchical temporal memory: Concepts, theory and terminology*. Whitepaper, Numenta Inc., 2006.
- [11] Kapuscinski, T., *Using hierarchical temporal memory for vision-based hand shape recognition under large variations in hands rotation*. Artif. Intell. Soft Comput., 272–279, 2010.
- [12] Kjellström, H., Romero, J., Kragic, D., *Visual object-action recognition: Inferring object affordances from human demonstration*. Computer Vision and Image Understanding, 2010.
- [13] Melis, W., Kameyama, M., *A study of the different uses of colour channels for traffic sign recognition on hierarchical temporal memory*, in: Fourth International Conference on Innovative Computing, Information and Control (ICICIC), pp. 111–114, 2009.
- [14] Metta, G., Gasteratos, A., Sandini, G., *Learning to track colored objects with log-polar vision*. Mechatronics 14, 989–1006, 2004.
- [15] Mittal, A., Pagalthivarthi, K., *Temporal bayesian network based contextual framework for structured information mining*. Pattern Recognition Lett. 28, 1873–1884, 2007.
- [16] Rozado, D., Rodriguez, F., Varona, P., *Optimizing hierarchical temporal memory for multivariable time series*. In: Artificial Neural Networks – ICANN 2010. Springer, pp. 506–518, 2010.
- [17] Sandini, G., Tagliasco, V., *An anthropomorphic retina-like structure for scene analysis*. Comput. Graph. Image Process. 14, 365–372, 1980.
- [18] Stenger, B., Thayananthan, A., Torr, P., Cipolla, R., *Hand pose estimation using hierarchical detection*. In: Computer Vision in Human–Computer Interaction. Springer, pp. 105–116, 2004.
- [19] Qiao, L., Chen, S., Tan, X., *Sparsity Preserving Projections with Applications to Face Recognition*, Pattern Recognition, Elsevier, 43, pp. 331–341, 2010.
- [20] Martinez, T., Berkovich S., Schulten K., *"Neural-Gas" Network for Vector Quantization and its Application to Time-Series Prediction*, IEEE Trans. on Neural Networks, 4, pp. 558–569, 1993.

ИЕРАРХИЯЛЫҚ ТЕМПОРАЛЬДЫҚ ЖАДЫ: БЕЙНЕТАНУДЫҢ ЖАҢА ӘДІСІ

Ч. А. Кеншімов, Д. Еділхан

ҚР БҒМ Ақпараттық және есептеуіш технологиялар институты, Алматы, Қазақстан

Тірек сөздер: бейнетану, НТМ, нейрондық желі.

Аннотация. Мақалада иерархиялық темпоральдық жады құрылымына негізделген жаңа бейнетану технологиясы қарастырылады. Иерархиялық темпоральдық ақпарат өңдеу барысында неокортекс, яғни ми қабығының бөлігінің құрылымдық және алгоритмдік қасиеттерін қолданатын жаңа технология.

Ұсынылған технология адамның шешуіне тән осындай есептерді иерархиялық жады құрылымында (ми қабығының бөлігінде) тануда және модельдеуде қолданылады. Сондықтан да иерархиялық темпоральдық жады когнитивтік есептерді шешуде адам қабылетіне әлдеқайда жетік есептеу машиналарын құруда қолданылады. Иерархиялық темпоральдық жадын нейрондық желінің бір типі ретінде қарастыруға болады. Шындығында, неортекстің сәулеттік бөліктерін модельдеуде қолданылатын кез келген жүйені нейрондық желі деп қарастыруға болады. Иерархиялық темпоральдық жады ерекшелігі ретінде аймақтарда иерархиялық орналасқан бағыналар мен қабаттардағы нейрондарды модельдеуге ұсынылатындығын айтуға болады. Атап айтсақ, иерархиялық темпоральдық жады нейрондық желінің жаңа типі. Иерархиялық темпоральдық жады әрбіреуі оқыту және сақтау есептерін шешетін көптеген түйіндерден құрылған ағаш тектес иерархиялық форма. НТМ ақпаратты иерархия осьтері бойынша сақтайды. Сонымен, мақалада НТМ-ге негіз болатын теория қарастырылады және «оқу», «тану», «болжау», «тәртібі» сияқты есептердің мүмкіндіктері зерттеледі.

Поступила 22.05.2015 г.