

Модель

Для разработки сети BCNN мы использовали библиотеку собственной разработки (TNeuronalNet), написанную на языке Object Pascal (Delphi). Обучение и отладка проводилась на производительном 4х-ядерном компьютере с процессором Intel-Xeon (16Гб RAM), а написание и отладка кода на Нетбуке с процессором Intel-Celeron. Исходный код отлаженной библиотеки находится на сайте Лаборатории психофизиологии факультета психологии СПбГУ (<http://pfmethod.psy.spbu.ru/NeuroNet.htm>).

Нейросеть BCNN (Gorbunov I. Semenov P.) в базовом варианте имеет четырехслойную структуру с 2мя парами одинаковых по количеству нейронов слоев 1м и 4м и 2м и 3м (Рис 1).


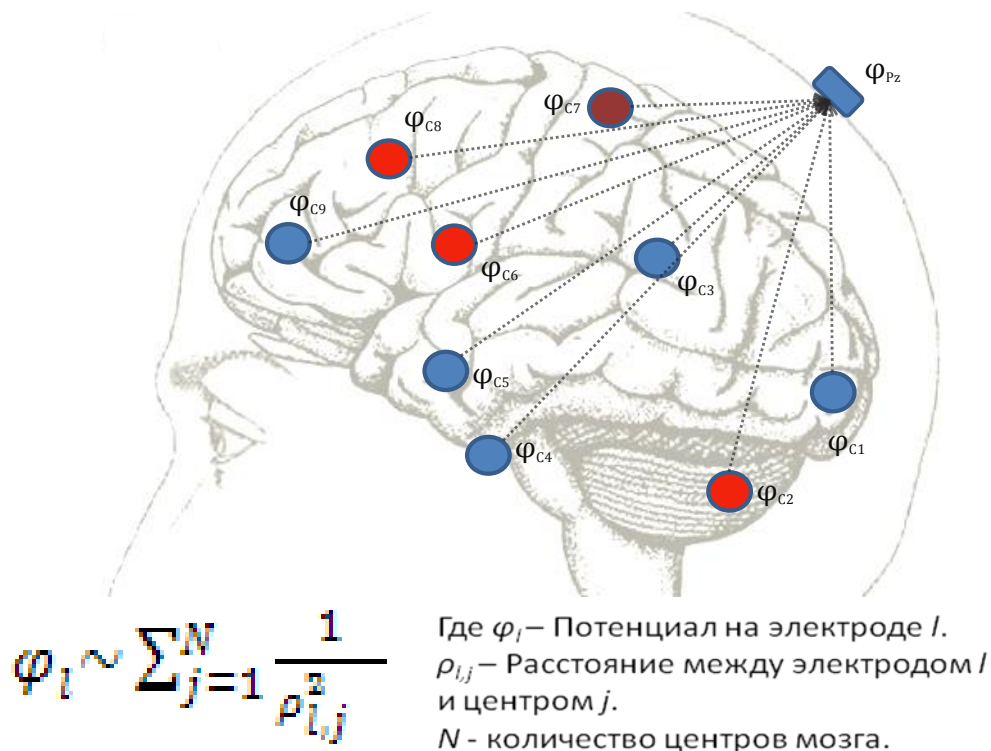


Рис 1. Схематическое изображение нейронной сети BCNN для построения модели взаимосвязей между центрами мозга (функционального коннектома). Изображена модель BCNN где $I_1 \dots I_n$ – нейроны, активация которых отражает потенциалы на электродах в начальный момент времени t_i . H_{11}, H_{12} – нейроны, активация которых отражает электрические потенциалы мозговых центров (показано только 2, но может быть и больше) в момент t_i . H_{11}, H_{12} – нейроны, активация которых отражает электрические потенциалы тех же мозговых центров после взаимодействия в момент t_{i+1} . O_1, O_n – потенциалы на электродах в момент t_1

Первый и четвертый (входной и выходной) слои содержат нейроны, активация которых должна соответствовать потенциалам на ЭЭГ электродах на поверхности головы. Второй и третий слои содержат нейроны, активация которых отражает суммарный биоэлектрический потенциал определенной области мозга. Несмотря на громадное упрощение модели структуры мозга, мы постарались сделать ее наиболее соответствующей нашему пониманию процессов биоэлектрической активности. В соответствие с этим активация нейрона может иметь положительный или отрицательный потенциал. Мы

выбрали гиперболический тангенс как активационную функцию (отражающую скачек между поляризацией дендритного дерева и сомы нейронов центра). Этот выбор мы сделали так как исходя из теорий происхождения ЭЭГ (Гусельников В. И. 1976, Зенков Л. Р. 2011, Niedermeyer E. and da Silva F.L. 2005) можно предположить, что поверхностная ЭЭГ формируется в основном благодаря деполяризационным и гиперполяризационным процессам, происходящим на дендритных деревьях, которые с точки зрения авторов имеют более плавную временную природу и, за счет большого количества дендритов, более сильно отклоняющиеся от нуля потенциалы чем процессы, происходящие в аксонах. Следовательно, влияние на поверхностную ЭЭГ оказывает в большей степени активность нейрона до преобразования через скачковую (сигмоидную) функцию активации. Система связей между центрами мозга и электродами $3m$ (центры мозга) и $4m$ (электроды) слоями была выбрана исходя из закономерностей распространения электрического потенциала в объемном проводнике. То есть, влияние источника потенциала распространяется обратно пропорционально квадрату расстояния между источником и регистрирующим элементом (электродом).



$$\varphi_l \sim \sum_{j=1}^N \frac{1}{\rho_{l,j}^2}$$

Рис. 2. Схема вычисления потенциала на электроде в зависимости от электрических потенциалов центров мозга.

Процессы, происходящие при передаче возбуждения между центрами мозга изображены на рис. 3. В модели BCNN они математически эквивалентны передаче возбуждения между 2 и 3-им слоем. Однако если на нейронах 2 слоя вычисляется нелинейная активационная функция гиперболического тангенса, то на нейронах 3 слоя вычисляется линейная функция, так как ранее мы утверждали, что влияние электрических потенциалов центров на электроды выше, при деполяризации дендритных деревьев, то есть до передачи возбуждения на аксоны. Фактически активность нейронов третьего слоя линейно влияет на потенциал на электроде обратно пропорционально квадрату расстояния до него. Матрица расстояний между 1м и 2м слоями, является обратной, матрице связей между 3м и 4м слоями, то есть обратной матрице сопротивлений. В случае, когда количество центров и количество электродов не равно, обратную матрицу не вычислить, но можно вычислить псевдообратную матрицу (Беклемишев Д. В.:1983). Это позволяет вычислять состояние центров из состояний входных электродов с минимально возможной ошибкой.

Для придания анатомического сходства модели BCNN мы использовали карту Talairah при вычислении пространственных координат выбранных нами центров. Была взята карта, вокселей соответствующая модели LoReTa (Pascual-Marqui, R 2007). В данной карте содержится 2394 вокселя с соответствующими пространственными координатами. Воксели соответствуют основным скоплениям серого вещества мозга в модели атласа Talairah. Каждый воксел сопоставлен с определенной структурой мозга, и полем по Атласу Бродмана.

Список структур мозга, к которым принадлежат воксели приведен ниже:

- | | |
|------------------------------|-----------------------------|
| 1. Angular_Gyrus, | 12. Lingual_Gyrus, |
| 2. Anterior_Cingulate, | 13. Medial_Frontal_Gyrus, |
| 3. Cingulate_Gyrus, | 14. Middle_Frontal_Gyrus, |
| 4. Cuneus, | 15. Middle_Occipital_Gyrus, |
| 5. Extra_Nuclear, | 16. Middle_Temporal_Gyrus, |
| 6. Fusiform_Gyrus, | 17. Orbital_Gyrus, |
| 7. Inferior_Frontal_Gyrus, | 18. Paracentral_Lobule, |
| 8. Inferior_Occipital_Gyrus, | 19. Parahippocampal_Gyrus, |
| 9. Inferior_Parietal_Lobule, | 20. Postcentral_Gyrus, |
| 10. Inferior_Temporal_Gyrus, | 21. Posterior_Cingulate, |
| 11. Insula, | 22. Precentral_Gyrus, |

23. Precuneus,
 24. Rectal_Gyrus,
 25. Subcallosal_Gyrus,
 26. Sub_Gyral,
 27. Superior_Frontal_Gyrus,
 28. Superior_Occipital_Gyrus,

29. Superior_Parietal_Lobule,
 30. Superior_Temporal_Gyrus,
 31. Supramarginal_Gyrus,
 32. Transverse_Temporal_Gyrus,
 33. Uncus




Рис 3. Схема взаимодействия центров мозга исходя из матрицы связей между центрами

Список полей по Бродману, к которым принадлежат воксели приведен ниже:

Amygdala	Brodmann_area_11	Brodmann_area_28
Hippocampus	Brodmann_area_13	Brodmann_area_29
Brodmann_area_1	Brodmann_area_17	Brodmann_area_30
Brodmann_area_2	Brodmann_area_18	Brodmann_area_31
Brodmann_area_3	Brodmann_area_19	Brodmann_area_32
Brodmann_area_4	Brodmann_area_20	Brodmann_area_33
Brodmann_area_5	Brodmann_area_21	Brodmann_area_34
Brodmann_area_6	Brodmann_area_22	Brodmann_area_35
Brodmann_area_7	Brodmann_area_23	Brodmann_area_36
Brodmann_area_8	Brodmann_area_24	Brodmann_area_37
Brodmann_area_9	Brodmann_area_25	Brodmann_area_38
Brodmann_area_10	Brodmann_area_27	Brodmann_area_39

Brodmann_area_40
 Brodmann_area_41
 Brodmann_area_42

Brodmann_area_43
 Brodmann_area_44
 Brodmann_area_45

Brodmann_area_46
 Brodmann_area_47




Рис 4. Модель нейровизуализации вокселей BCNN.

Координаты 99 электродов в системах %10-20, 10-10% также были взяты из данной модели.

Fp1	F9	FC6	CPz	PO5
Fpz	F7	FT8	CP2	PO3
Fp2	F5	FT10	CP4	PO1
Nz	F3	T9	CP6	POz
SO1	F1	T7_T3	TP8	PO2
SO2	Fz	C5	TP10	PO4
IO1	F2	C3	P9	PO6
IO2	F4	C1	P7_T5	PO8
AF9	F6	Cz	P5	PO10
AF7	F8	C2	P3	O1
AF5	F10	C4	P1	Oz
AF3	FT9	C6	Pz	O2
AF1	FT7	T8_T4	P2	O9
AFz	FC5	T10	P4	O10
AF2	FC3	TP9	P6	CB1
AF4	FC1	TP7	P8_T6	CB2
AF6	FCz	CP5	P10	Iz
AF8	FC2	CP3	PO9	M1
AF10	FC4	CP1	PO7	M2

A1
A2
T1
T2

Для разработки модели необходимо было проверить ее возможности с точки зрения качества восстановления матрицы связей искусственной модели и найти оптимальное количество центров, с одной стороны отвечающее требованиям надежности, а с другой с максимально возможным количеством центров мозга для качественной нейровизуализации.

Для этого был произведен численный эксперимент, в котором строились модели взаимодействия нервных центров, которые циклически функционировали, передавая возбуждение по слоям нейронов от входного слоя (на электродах) и получая выходные значения активации (на поверхностных электродах). Далее выходные значения загружались на вход, и после активации сети получались следующие значения на выходе (поверхностных электродах). Производя эти действия в цикле, можно получить достаточно большую последовательность модельного ряда ЭЭГ, контролируя при этом, чтобы система не приходила к устойчивой точке и вариативность сигналов терялась бы. Далее матрица связей между центрами в модели запоминалась, веса инициализировались случайными числами и проводилось обучение новой модели BCNN на полученной последовательности. После каждого цикла обучения старая (запомненная) модель и новая (полученная при обучении на сгенерированном сигнале) сравнивались между собой, с помощью вычисления коэффициента корреляции между массивами межцентровых связей, преобразованными в линейный вектор данных. Результаты таких проверок приведены в графиках на рис 5. Как видно на графиках, по мере обучения коэффициент корреляции увеличивается до корреляций от 0,89 до 0,95. В модели, представленной на рисунке 4 и 5 было выбрано 30 центров и 29 электродов. В дальнейшем мы использовали модель, состоящую из 30 центров.

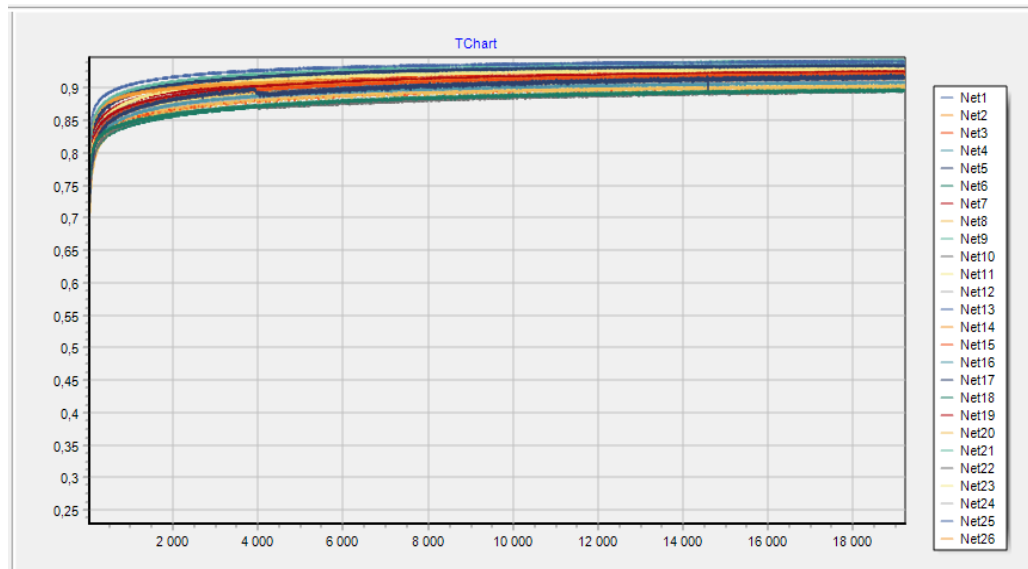


Рис. 5 Процесс возрастания коэффициента корреляции между матрицами связей модели, порождающей поверхностную ЭЭГ и модели, восстанавливающей эту матрицу по порожденному поверхностному сигналу ЭЭГ. Всего генерировалось и обучалось 30 таких моделей. Длительность обучения до 18000 циклов обучения. Конечные корреляции между исходной и восстановленной матрицей варьируют от 0,89 до 0,94 (значимость такой корреляции менее 10^{-5}). Такие данные на наш взгляд говорят о хорошем качестве восстановления матрицы связей моделью BCNN. При этом не наблюдается переобучения, которое обнаруживалось бы при снижении корреляции между массивами связей по мере минимизации успешности предсказаний временного ряда ЭЭГ, то есть по мере обучения.

При варьировании количества центров было обнаружено, что качество распознавания матрицы связей (корреляция между двумя матрицами связей) существенно уменьшается при увеличении количества центров вводимых в модель. Например, корреляции между восстановленной матрицей и генерирующей матрицей варьируют после обучения в районе 0,5 при 55 центрах и спускаются до 0.0018 при задействовании всех 2394 вокселей как отдельных центров. Однако корреляция 0.0018 в данном случае тоже является значимой на уровне $p < 0.01$ так как количество связей в такой матрице достигает 2394^2 .

Как выяснилось, существенным фактором в качестве восстановления связей является низкая скоррелированность матриц расстояний между центрами и электродами, так как центры, находящиеся близко друг к другу труднее распознаются. Поэтому рационально выбрать координаты центров,

объединяющих воксели мозга по данному принципу. С помощью кластерного анализа (метод k-средних) были рассчитаны кластерные решения для разного количества групп вокселей, объединенных по принципу близости координат и матриц сопротивлений вокселей и электродов и максимальной их дальности между группами. Оптимальность таких решений проверялась дисперсионным анализом. Чем выше эффект влияния кластеров на дисперсию матриц сопротивлений между электродами и центрами, (измеряемый средним F-критерием Фишера по всем связям), тем лучше кластерное решение. Оценивались решения от 28 до 80 кластеров. На рисунке 6 видно, что хорошие кластерные решения – 30, 33, 39, 42, 50, 55 и 66.




Рис. 6. Кривая сравнения качества разделения на кластеры вокселей карты мозга. По оси X – количество кластеров, по оси Y - сумма F-критериев Фишера, оценивающих влияние на дисперсию зависимых переменных (координат вокселей и сопротивлений между ними и электродами) данного кластерного решения.

В нашу модель мы пока ввели 30, 39 и 55 кластерные решения и соответствующие матрицы связей. Все, входящие в кластер воксели в данной модели принадлежат 1 центру, который отображается вокселем, имеющим самую малую сумму расстояний до других вокселей в этом кластере, то есть

ближе всех к его центру. Кроме того в модели также присутствуют решения с центрами соответствующими вокселям в геометрическом центре каждой структуры мозга из вышепериведенного списка и в каждом поле по Бродману, разделенные отдельно на правые и левые полушария. Также возможно создание модели для 2394 центров соответствующих всем вокселям. Однако для текущих расчетов была выбрана модель с 30 кластерами – центрами.

При разработке модели мы обнаружили еще один метод, позволяющий улучшить качество распознавания матрицы связей при увеличенном количестве центров. Можно, вместо псевдообратной матрицы связей между первым слоем и центрами ввести дополнительный слой нейронной сети для обучения распознаванию активаций центров с помощью нейросетевого алгоритма. В результате нейросеть разделяется на 2 части обучаемые на разных этапах. На первом этапе на слой, представляющий центры мозга после преобразования загружаются случайные значения активаций. После этого от этого слоя распространяется возбуждение до выходного слоя электродов. Значения, полученные на выходном слое загружаются на входной слой и сеть активируется до слоя, представляющего центры до взаимодействия. Полученные активации центров сравниваются с загруженными вначале активациями и вычисляется рассогласование, которое является основой обучения подсети из первых 3х слоев. Таким образом, первые 3 слоя обучаются восстанавливать активацию центров, которая была причиной активации выходного слоя электродов. Такое, нелинейное преобразование может несколько улучшить качество восстановления активации центров по поверхностной активации электродов. Оказалось, что применение такого алгоритма при увеличении количества центров больше чем количество электродов, позволяет улучшить восстановление матрицы связей между центрами примерно на 10-15% величины корреляции. Однако для дальнейших расчетов мы не использовали данный алгоритм, но оставили такую возможность, встроив в разрабатываемое ПО необходимые опции.

Подбор скорости обучения.

В связи со сложной структурой сети, включающей в себя много слоев, обладающих разными функциями активации, было очень сложно подобрать оптимальные параметры скорости обучения сети. На это ушло много

времени, так как очень небольшие изменения скорости обучения на разных этапах обучения, и при различной амплитуде генерируемых сигналов могли полностью дестабилизировать процесс обучения, либо практически остановить его. В конечном итоге оптимальным оказался алгоритм, предложенный в статье (Рындин А. А., Ульев В. П. 2012) в котором скорость обучения η на каждом шаге модифицируется исходя из параметра представляющего максимум отношения абсолютного отклонения ошибки на выходе сети к абсолютному отклонению от нуля целевого значения. То есть формуле: η

$$M = \max_{i,N} |Err| / |D|$$

(1)

$$\eta = K * M \quad (2)$$

Max – вычисление максимального значения по всем нейронам

Где Err - Ошибка (Разность между целевым и полученным значением) на нейроне i

D – Целевое значение для нейрона i

K – Коэффициент выбираемый произвольно, обычно для наших задач значение $0.0001 < K < 0.1$.

В модель была заложена возможность обучения не только на ближайших по времени векторах потенциалов ЭЭГ, а увеличение шага предсказания на N выборок вперед. При этом ЭЭГ сглаживалась, так, что следующий вектор, вычислялся усреднением через окно Гаусса, по величине равное половине расстояний между исходной и прогнозируемой выборками.

Обучение BCNN на данных ЭЭГ

ЭЭГ, перед обучением сети BCNN было по возможности очищено от артефактов движений глаз с помощью регрессионных уравнений от канала Электроокулограммы, который фиксировался от дополнительного отведения над ведущим глазом. В программе WinEEG v.2.93 устанавливались фильтры 1,6Гц-30Гц и полосовой фильтр 45-55Гц. Далее файл ЭЭГ экспортировался в файл формата чисел с плавающей точкой, который потом загружался в программу BCNNWin.exe разработанную для обучения нейросети. Программа была разработана так, чтобы была возможность загружать

одновременно несколько файлов, содержащих кривые ЭЭГ с маркерами фрагментов и метками синхронизации с экспериментальными событиями.

Для проверки качества обучения и надежности распознавания матриц связей на случайных участках ЭЭГ различной длины производилось обучение BCNN с разными временными шагами. BCNN активировалась вектором потенциалов на электродах ЭЭГ, а обучалась вектором, полученным из ЭЭГ через N выборок начиная с максимальной частоты считывания ЭЭГ в 500Гц. Проверялись сдвиги от 1 до 100 выборок, то есть от 500 до 5Гц. Было обнаружено, что наиболее высокие корреляции измеренной и восстановленной ЭЭГ получаются на моделях, обученных с минимальным шагом 1 выборка. Здесь корреляция варьирует от 0,75 до 0,9 практически независимо от длины обучающего участка ЭЭГ.

Для длинных по времени шагов, предсказание снижается, что отражается на снижении средней корреляции между восстановленным рядом ЭЭГ и исходным и снижении ошибки предсказания - Рис.8.




Рис. 8 Зависимость успешности восстановления ЭЭГ сигнала от длительности предсказания. По горизонтальной оси – количество шагов предсказания от 17 до 100 шагов (29-5Гц, 42-200мс). По вертикальной оси – Корреляция – синий график и ошибка – красный график. (На данные проверки затрачено более 32 часов машинного времени)

Усредненные значения по корреляциям и ошибкам считались по 7 обучаемым моделям для каждого сдвига.

При проверке на независимой выборке (обычно на участке, следующем сразу за выбранным для обучения участком, такой же длины) обнаруживалось частое снижение корреляции и увеличение ошибки, однако

явных и длительных процессов переобучения сети не наблюдалось. Для исключения явлений переобучения, мы заканчивали обучение после N циклов обучения, если ошибка при проверке на внешней выборке была меньше, чем ошибка на обучающей выборке. Если это условие не выполнялось, мы продолжали обучение до выполнения условия. Обычно условие выполнялось почти сразу после выбранного количества циклов. Наиболее частая задержка до выполнения условия составляла менее 3% от общего количества циклов обучения. На рисунке представлена динамика обучения нейросети на участке фонового замера ЭЭГ 1,5сек. с закрытыми глазами. Красной линией представлены проверки восстановления следующего вектора ЭЭГ по предыдущему с временным сдвигом в 2 мс (одна выборка ЭЭГ) на внешнем участке, на котором обучение не производилось. Зеленым цветом представлена динамика ошибок прогноза на внешней выборке. Синяя и желтая линии – корреляция и ошибка на тренировочной выборке. Видны небольшие участки переобучения сети, когда красная линия смещается существенно ниже синей.

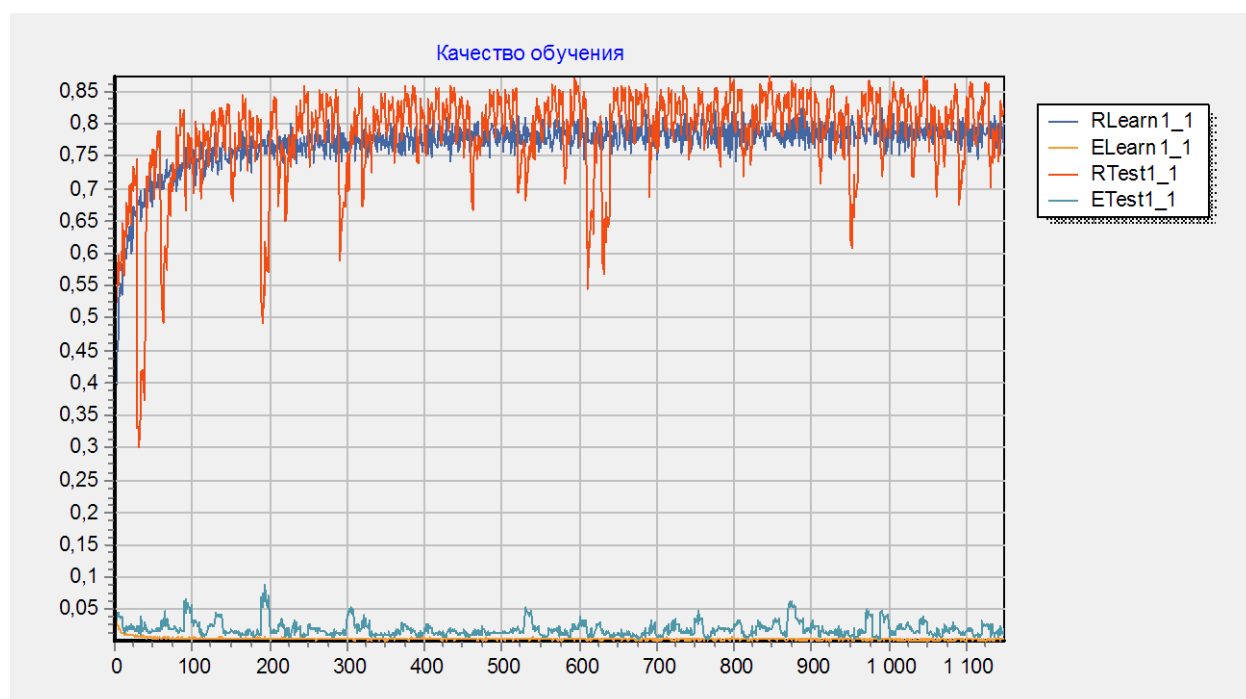


Рис 9. Динамика обучения BCNN на ЭЭГ и проверок на внешнем участке ЭЭГ. Длина обучающего и тестового участков 1,5с. Временной сдвиг прогноза 2 мс.

Ниже, на рисунке 10 показаны результаты обучения на участке ЭЭГ со сдвигом временного прогноза 32мс. То есть модель училась предсказывать

сглаженный гауссовым окном шириной 32мс. Вектор через 32мс или 16 выборок ЭЭГ.


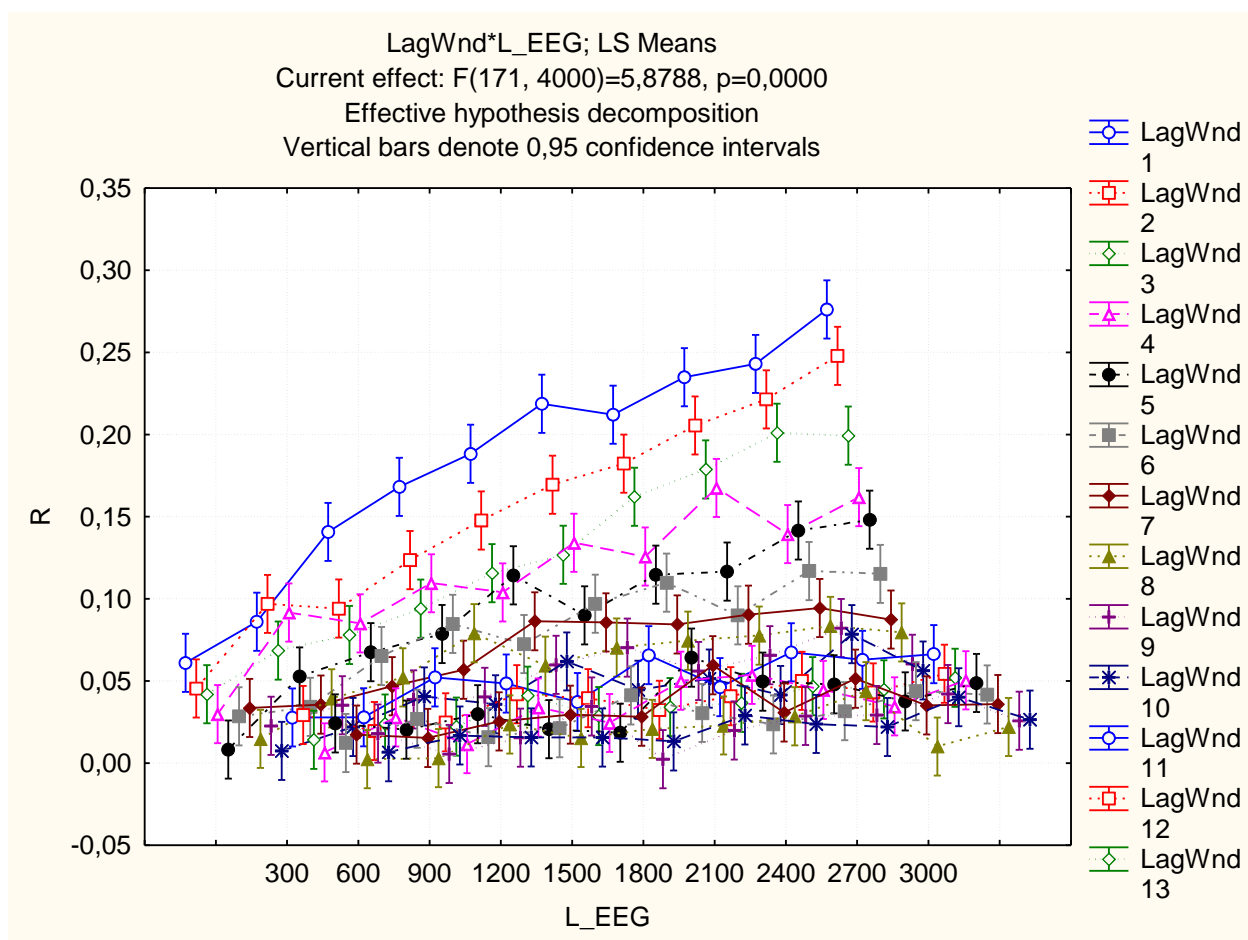


Рис 10. Динамика обучения BCNN на ЭЭГ и проверок на внешнем участке ЭЭГ. Длина обучающего и тестового участков 48с (96000 выборок ЭЭГ). Временной сдвиг прогноза 32 мс (16 выборок ЭЭГ или 31Гц).

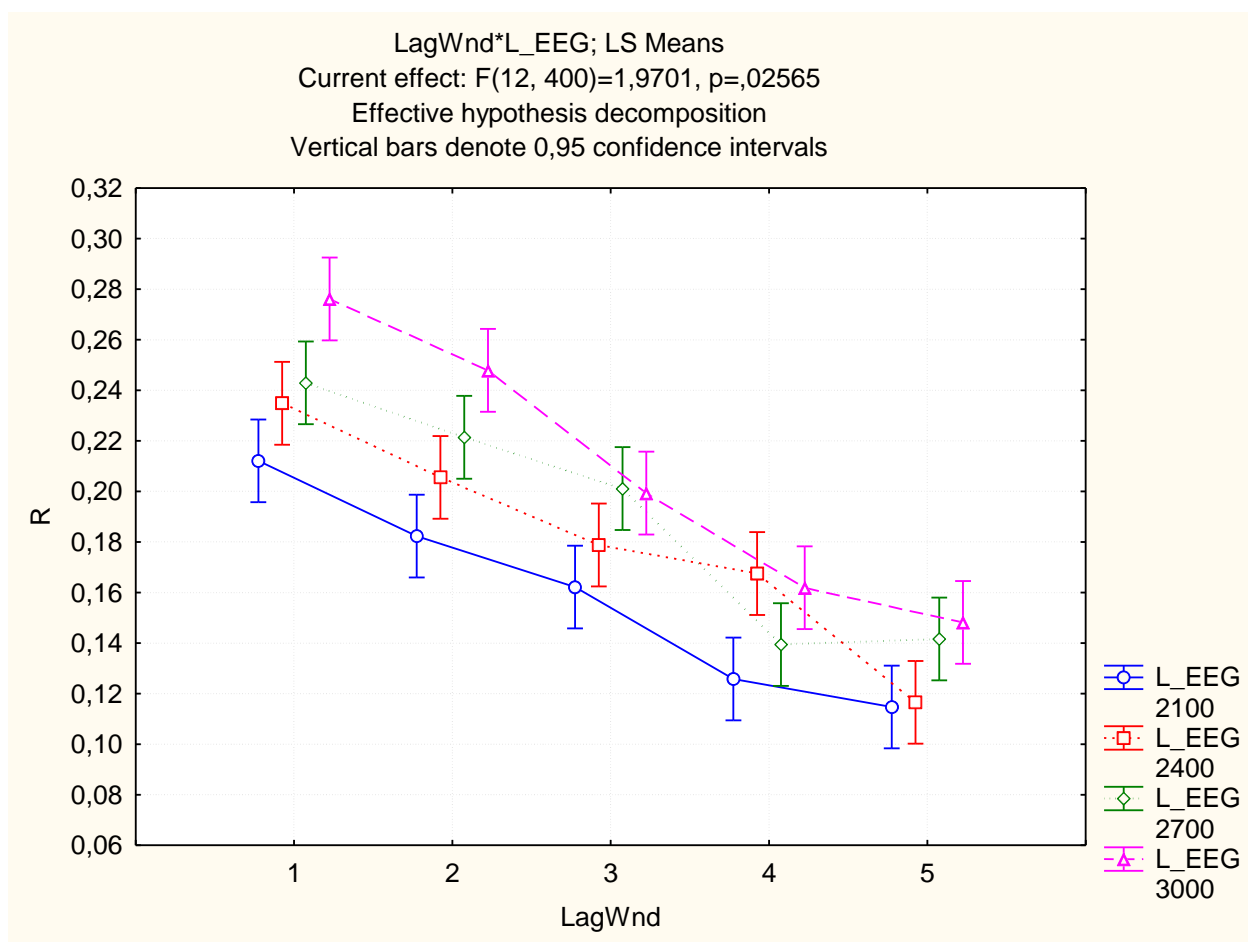
Для проверки надежности распознавания матрицы связей необходимо было проверить корреляции между матрицами, обученными на одном и том же участке с помощью сетей, которые начинали обучение из разных, случайных матриц связей. Выяснилось, что надежность достаточно низка (корреляции между разными моделями менее 0,1) если BCNN обучались на малых выборках ЭЭГ, от 50 векторов (длительность участка ЭЭГ при шаге в одну выборку 0,1 секунды). При увеличении обучающих выборок до 3000 векторов (длительность ЭЭГ при шаге в одну выборку 6 секунд), корреляции между моделями уже варьировали вокруг 0,6.

Следовательно, для увеличения надежности измерений, необходимы выборки ЭЭГ длиной более 3 секунд. Возможен также вариант обучения модели на одном длинном участке, а потом «доучивания» той же модели на более коротких участках для сравнения.

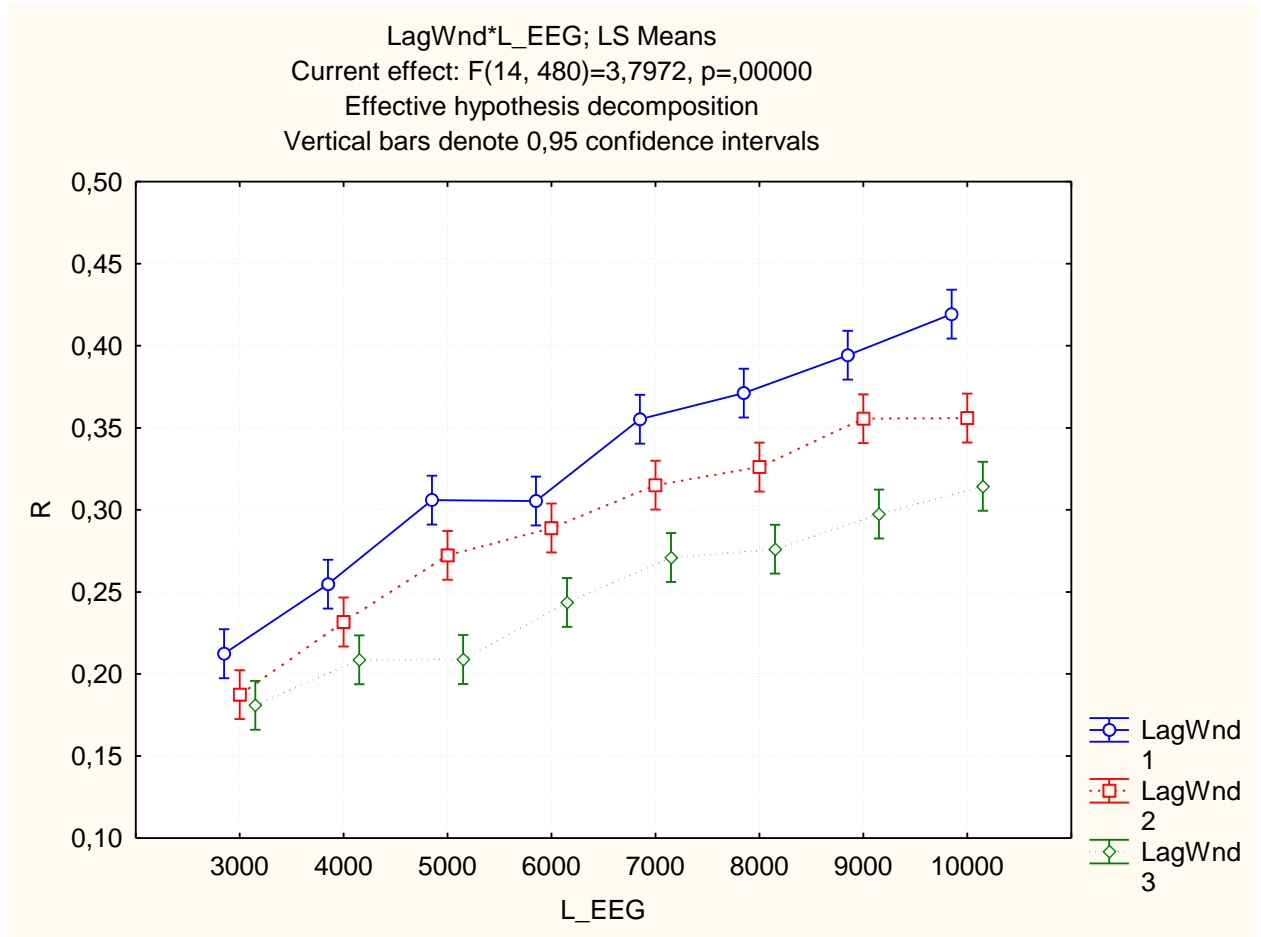
При увеличении шага обучения корреляции между восстановленными матрицами связей не имели явной тенденции.




Зависимость корреляции между матрицами связей, полученными при обучении BCNN на разных по длине отрезках ЭЭГ (ось X L_EEG) и от шага предсказания LagWnd



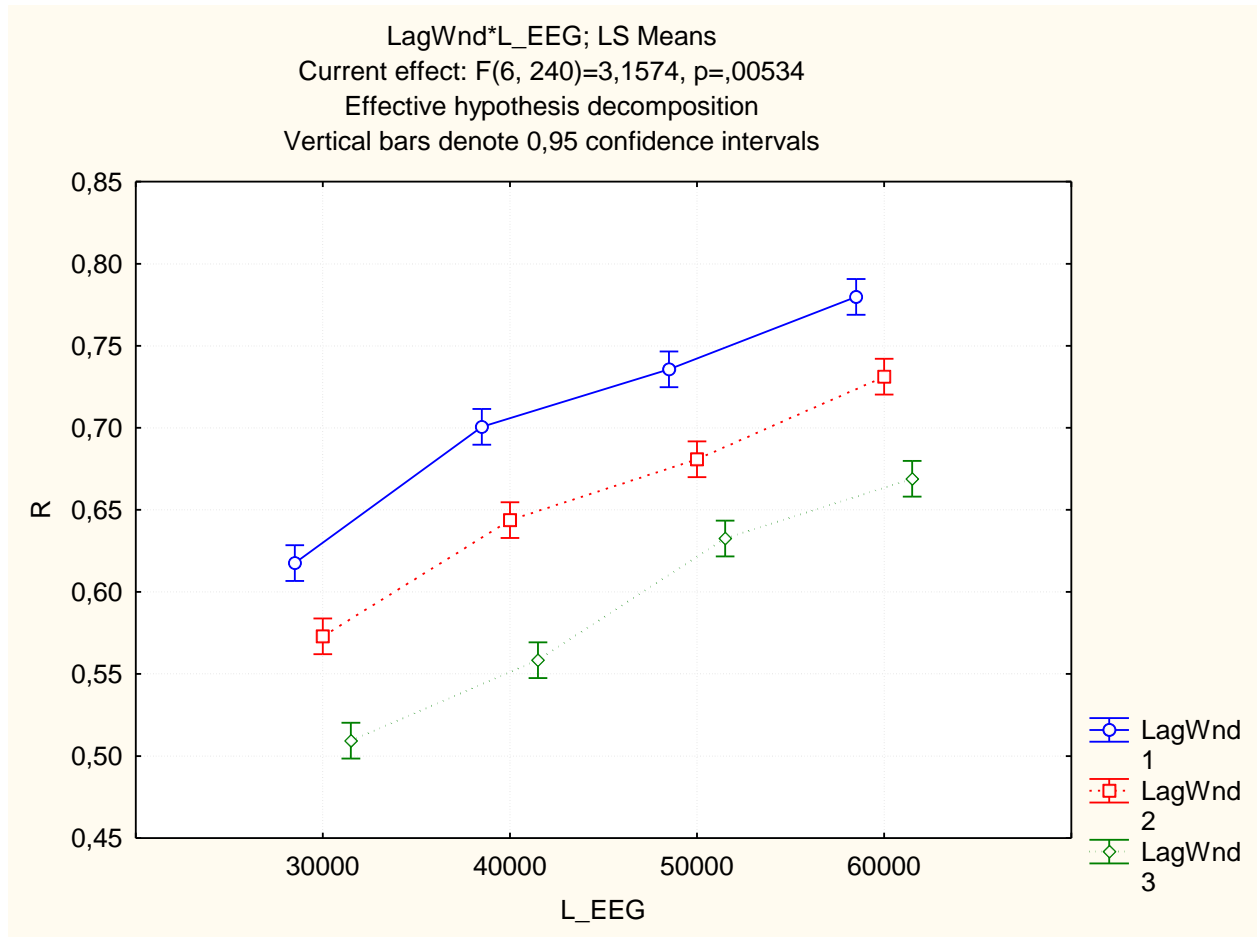
Зависимость корреляции между матрицами связей, полученными при обучении BCNN на разных по длине отрезках ЭЭГ (ось X L_EEG) и от шага предсказания LagWnd только для шагов от 1 до 5 и для длин отрезков 2100-3000



Зависимость корреляции между матрицами связей, полученными при обучении BCNN на разных по длине отрезках ЭЭГ (ось X L_EEG) и от шага предсказания LagWnd только для шагов от 1 до 3 и для длин отрезков 3000-10000 выборок

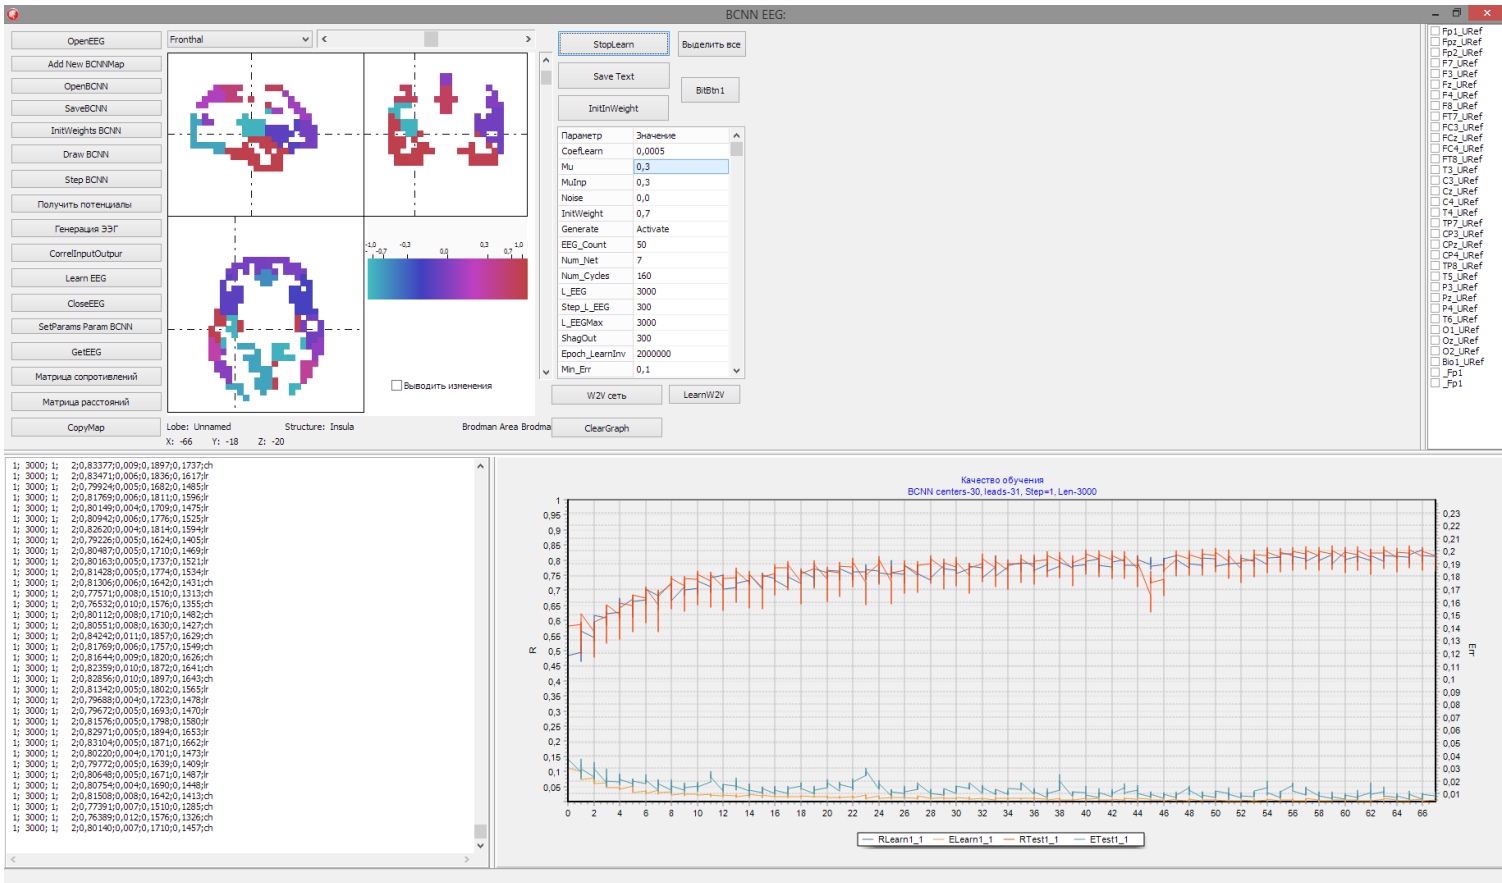


Зависимость корреляции между матрицами связей, полученными при обучении BCNN на разных по длине отрезках ЭЭГ (ось X L_EEG) и от шага предсказания LagWnd только для шагов от 1 до 3 и для длин отрезков 10000-30000 выборок



Зависимость корреляции между матрицами связей, полученными при обучении BCNN на разных по длине отрезках ЭЭГ (ось X L_EEG) и от шага предсказания LagWnd только для шагов от 1 до 3 и для длин отрезков 30000-60000 выборок

Как видно, при длине ЭЭГ 60000 выборок, то есть с частотой 500 Гц 120сек., надежность восстановления матрицы связей доходить до средней корреляции 0,77 между 7 восстановленными матрицами с разных случайных начальных состояний нейросети, на одном участке ЭЭГ.



Внешний вид программы для BCNNW.exe при обучении нейросети предсказанию ЭЭГ.