

学習効率向上に向けた 脳波に基づく VR-HMD ユーザの嗜好性推定

今別府 万大¹ 長谷川 達人¹

概要: 近年、アクティブ・ラーニングや反転学習という授業形態により、学習者の主体的な学習を促す取り組みが見られる。しかし、これらの授業形態では学習者自身の授業への参加意欲や、教育コンテンツの良し悪しが学習効率に影響する。授業形態以外を工夫する観点として、e-Learnig 環境での自主学習環境において学習者自身のやる気を向上させるシステムを実現することで、学習効率向上の図る方法がある。このことから、学習者の好みに応じた教示者画像の生成、および生成画像を VR 空間上で教示者アバタとして投影、授業の教示者の置き換えを行うシステムの開発を目指す。そのための第一段階として、本研究では、学習者の嗜好性を脳波から推定するために実現可能性の基礎検証を行う。実験では表示される顔画像を見た際の脳波の計測を行う。その後、貪欲法を用いて特徴量選択し、機械学習で「好き」「好きでない」の2値分類で嗜好性推定を2種類の方法で行った結果、画像を相対的に比較するような形で嗜好性推定を行った方が平均推定精度の向上が見られた。また、特徴量について見てみると嗜好性の推定において β 波や β/α が選択される傾向が多いことが分かった。

Preference estimation of VR-HMD users based on EEG for improving learning efficiency

MAHIRO IMABEPPU¹ TATSUHITO HASEGAWA¹

1. はじめに

近年、アクティブ・ラーニングや反転学習という授業形態により、学習者の主体的な学習を促す取り組みが見られる。前者は授業内容を従来の授業のように受動的に話を聞いたりするのではなく、学習者自らが問題解決や話し合いなどをしたり能動的に学ぶことで学習意欲の向上させる授業形態である。後者は学びのインプットとアウトプットの間を反転させることで、学習者自身が予習を自主的にする環境が構成され、結果として学習意欲が向上するような授業形態である。しかし、これらの授業形態では学習者自身の授業への参加意欲や、教育コンテンツの良し悪しが学習効率に影響する問題がある[1]。特に反復授業の予習に用いられる e-Learning では、学習者のドロップアウト率が高い。その理由の一つに、学習者自身が学習することを先延ばしにしてしまうことが挙げられている[2]。このようなことから、授業形態の工夫以外の観点からも、学習者自身のやる気を向上させるシステムが実現できれば、e-Learning 学習などにおいて学習者のドロップアウト率の減少ないしは、学習意欲の向上につながることで学習効率向上の効果が見込めると考えられる。

我々は、学習者の好みに応じた教示者画像の生成、および生成画像を VR 空間上で教示者アバタとして投影、授業

の教示者の置き換えを行うシステムの開発を目指し、これによる e-Learning 環境を想定したやる気および、学習意欲や効率の向上を目指している。実現のための第一段階として、本研究では、学習者の嗜好性を脳波から推定するための実現可能性の基礎検証を行う。

2. 関連研究

2.1 生理学的研究

脳活動の研究分野では、学習活動時等にやる気があると脳内でドーパミンが分泌されることが分かっている[3]。ドーパミンは意欲や動機づけに関連する神経伝達物質で、Takahashi らの研究[4]では恋愛関係を持つパートナーの写真を見たときに分泌されることも確認されている。また、Salimpoor らの研究[5]では好きな音楽を聴いたときにドーパミンが分泌されることも確認されている。そのため、好みの音楽を聞くと学習意欲が増加し、集中力が向上することにつながる可能性が考えられる。

2.2 VR を用いた学習意欲向上

Ott らの研究[7]では、教育における没入型 VR と VR-HMD の教育・学習への使用に関する調査が行われた。これによると、VR の利点として没入感による VR 空間内オブジェクトやイベントを直接感じられる点、実際には危険なことを VR 空間で行うことで、安全に学習及び経験ができ

¹ 福井大学大学院工学研究科知識社会基礎工学専攻情報工学コース
Graduate School of Engineering, University of Fukui

る点を上げている。また、ゲーム的なアプローチによって学習者の興味・関心とモチベーションが高まりサポートされる学習環境の範囲が広がるとしている。

Wang の研究[8]では、物流機器アプリケーション教育や管理に VR (仮想現実技術) を導入することによって、従来の教育方法のテキスト、ビデオや写真を見せるだけのものよりも、学習者の学習意欲の向上が見られた。これは、VR の没入感や臨場感によって学習者の関心が高まったものだとしている。

2.3 人の嗜好性

人の嗜好性に関する研究として、Kang らの研究[9]がある。この研究では、人の見た目の好み为社会での友人や仲間づくり、政治的な勝敗への影響があるとして、好みの顔を見た時の脳波への影響を調査している。この実験では、被験者が男女の画像を受動的に眺める場合(passive task) と、能動的に好みの画像を選んでもらう(active task) という作業を行い、計測実験を行っている。基礎検証では、被験者が選択した好みの顔画像に対して、男女の性別の違いで選択する画像の差が出るのか、画像の表示順序が選択する好みの顔画像に影響するかを調査した結果、どちらの場合も影響はないことが示されている。また、脳波の分析では、 α 波について顔の好みとの関連性が示された。

Lindsen らの研究[10]では、人の見た目への主観的な嗜好選択における脳活動のパターンを明らかにすることを目的として調査を行っている。計測実験は用意された顔画像を見てもらい、最も「会って話したい」顔画像を選ぶ作業を行った。なお、この実験の表示顔画像はコンピュータで生成されたものであった。脳波の分析の結果、視覚的な嗜好




図 1. 嗜好性推定手法の概要



図 2. 使用機器 (左: muse, 右: myBeat)

において前頭部の θ 波と後頭部の γ 波への影響が示された。

以上を踏まえ、人は自身の嗜好を選択する際に、何らかの脳波変化が起こることが分かる。そのため、嗜好性推定において脳波を用いることは有効な手段だと考えられる。

2.4 本研究の位置づけ

本研究の最終的な目的は、e-Learning やビデオ学習環境に焦点を置き、学習者自身のやる気および学習意欲を向上させるシステムを実現することである。学習時には VR を装着して学習を行い、VR 空間内に表示される教示者を学習者の嗜好性に合わせたキャラクタの置き換えを行う。それにより、VR の学習意欲の向上効果や、好みの教示者表示によるドーパミンの分泌およびやる気向上効果を用いて学習意欲向上を目指す。本研究では以上の目的を達成するため、学習者の嗜好性を脳波から推定するための基礎検証を行う。脳波から学習者の嗜好性が推定できることで、学習者の潜在意識や心理状態を反映したキャラクタ画像が設定できるようになる。また、学習者自身が手動で嗜好性を設定する場合よりも、画像の表示方法によっては選択の手間の削減ができる。

3. 提案手法

3.1 概要

提案手法の概要を図 1 に示す。被験者はウェアラブルセンサを装着し、顔画像を見てもらう。そのとき、脳波など生体情報の計測を行う。その後、計測データから特徴量を抽出、及び分析し特徴量選択を行い機械学習で被験者ごとに嗜好性の推定を行う。なお、特徴量選択には貪欲法を用いて行う。各画像の嗜好性推定は、その画像が「好き」「好きでない」の 2 値分類で行う。嗜好性推定の際には各データに対して推定する場合と、相対的なデータの内、どちらが「好き」かを推定する 2 種類の場合を行った。

3.2 使用機器

計測には図 2 に示す簡易脳波計 muse とウェアラブル心拍センサ myBeat を用いる。muse とはヘッドバンド型簡易脳波計であり、EEG や頭部の加速度等が簡易計測できる。脳波計には様々なものが存在するが、その多くは頭部全体に電極を貼り付けるものである。それらのタイプの脳波計は、詳細な脳波の解析には向いているが、価格が高価であることや、計測毎に電極を張り直す必要があるため手間やストレスがかかるなどの問題が懸念される。また、本研究では VR-HMD を装着した状態を想定しているため、頭部全体を覆うタイプの脳波計では計測が困難であることも考えられる。そのため、前述した脳波計に比べ安価で装着がしやすく、VR-HMD を装着した状態でも計測可能な muse を採用した。

muse には、頭部の 4 カ所それぞれ TP9(左耳付近)、TP10(右

表 1. 特徴量

センサ	計測データ	特徴量	特徴量数
muse	TP9	各センサ部位の	平均, 最大, 最小, 中央値, 標準偏差 β/α における平均, 最大, 最小, 中央値, 標準偏差 FFT(Raw データ)の最大, 最小, 平均
	AF7	EEG の Raw データ	
	TP10	α 波, β 波, γ 波,	
	AF8	δ 波, θ 波	
	AUXR	EEG の Raw データ	
myBeat	心拍周期(RRI), 心拍数(HR)	平均値, 最大値, 最小値, 中央値, 標準偏差	10
合計			167

耳付近), AF7(左前頭部), AF8(右前頭部)と AUXR(右補助電極)1 つから脳波を計測可能なセンサ, 加速度センサ, ジャイロスコプ等が搭載されている. なお, 脳波を計測する電極 AF7, AF8 の位置は装着者の頭部サイズによって 10/20 法の FP1 及び FP2 に近い場合があるとされる. なお, 本研究ではこれらのセンサデータを Mind Monitor²というアプリを用いて計測する.

myBeat は小型・軽量のウェアラブル心拍センサである. 心臓の電気信号を直接受け取ることで高精度に心拍周期をとらえ, 取得データから自律神経バランスなどの心拍変動解析を行う. 胴体みぞおち付近に装着し肌に直接触れているベルトから心拍計測する. また, 装着後は無線接続のため, 計測時に装着者の動きを妨げる可能性は少なく, ストレスや設備コストも少なくてすむ. myBeat は心拍周期を測定可能で, RRI から LF/HF などの特徴量も計測可能である. 本研究では, 人の心理状態が心拍変動に影響を与えることから myBeat を補助的に使用する. また, 特徴量の抽出には心拍周期(RRI)と心拍(HR)の計測データのみを用いる.

3.3 計測データ・抽出特徴量

muse と myBeat から得られる計測データは, それぞれ 5 つの電極で測定される脳波(EEG)と, 心拍周期(RRI)である. これを各画像が表示される間の 3 秒間単位で集約した特徴量に変換し, 表 1 に示すような特徴量を抽出する. 抽出する特徴量は muse からは 157 種, myBeat からは 10 種の合計 167 種類である.

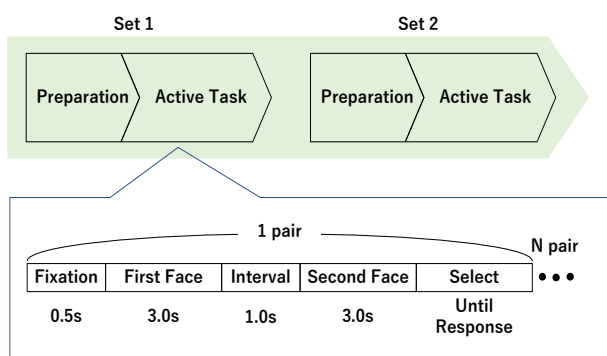


図 3. 計測実験の流れ

muse での計測は Mind Mointor というソフトウェアを用いる. 計測される値はそれぞれの電極での Raw データや, 電極 AUXR 以外では α 波, β 波, γ 波, δ 波, θ 波である. これらの計測値の基本統計量に加えて, ストレスや思考する集中度合いなどを示す[11]ことから, β/α の値の統計量も算出する. また Raw データに FFT (Fast Fourier Transform) 処理を施したデータの統計量も特徴量として用いる. myBeat からは心拍周期(RRI)と心拍(HR)のデータの統計量の特徴量として用いる.

3.4 機械学習

機械学習アルゴリズムには SVM(Support Vector Machine)を用いて嗜好性推定を行った. SVM は最大マージンの超平面を探索する機械学習アルゴリズムである. マージンは, 超平面から複数の点までの最小距離として定義され, 各クラス間のサポートベクトル間のマージンを決定境界として超平面を決定する. 本研究では, Python の scikit-learn を用いて, 機械学習を行った. 学習の際に使用したパラメータは, gamma を”auto”としその他のパラメータはデフォルト値のまま用いた.

機械学習で推定を行う際に推定に有効な特徴量を貪欲法により探索する. 本研究の貪欲法では, ある特徴量を機械学習モデルの入力とした際に, その推定精度が最良になるような特徴量の組み合わせを選択し, それを推定精度が向上しなくなるまで続けるものとなっている. これにより, 最良の推定精度が出るような, 特徴量の組み合わせを選択できる. なお, 今回は選択される特徴量数を最大 2 とした.

4. 計測実験

4.1 実験概要

今回, 各被験者の嗜好性を測るために, Kang ら[9]の Active Task を参考に実験手順を決定した. Active Task は, 提示された人物写真を見た際の脳波を計測するための作業である. この作業では, 用意された画像の中でペアとなった 2 つの顔を順番に提示し, その後表示された 2 つの内どちらが被験者の好みであったか選択を行うものとなっている. 本研究では, この Active Task をもとに図 3 のような流

² <https://mind-monitor.com/>[2020 年 4 月 23 日最終検索日]




図4. 実験計測の様子(左: VR-HMD, 右: PC モニタ)

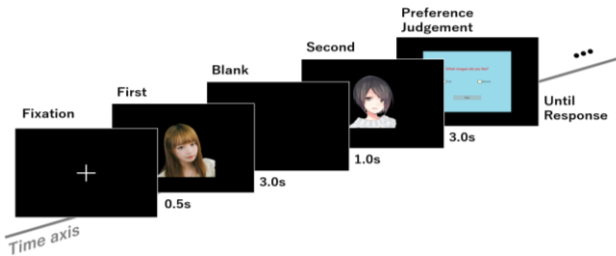


図5. 計測アプリ内での画像表示の流れ

れで実験を行った。Preparation ではウェアラブルセンサ等の装着を行い、センサデータが安定するまで安静にしてもらい。その後 Active Task による計測実験を行う。これを1セットとして各被験者2セット行う。画像の表示には図4のように VR-HMD と PC モニタの2種類を採用し、Set 1 で VR-HMD, Set 2 で PC モニタによる計測を行った。また、Kang ら[9]の Active Task では、表示画像は人物写真のみであったが、バーチャルキャラクターの教育における利用可能性を探るためイラスト画像と人物写真を表示画像に用いた。

本研究の実験では、イラスト画像12枚と人物写真12枚をそれぞれ6枚ずつに分け、イラスト画像と人物写真が合計12枚のグループを2つ用意した。画像は12枚の中から2枚の組み合わせが生成され、生成された組の中から図5のように1枚ずつ3秒間順に表示される。1組の画像が全て表示された後、表示された画像の内、どちらが好みであったかを選択する。これを ${}_{12}C_2 = 66$ 回行ってもらい。この作業を VR-HMD 上で行った後に、PC モニタ上でも行った。

被験者は20代健康男性8名である。全計測データ数は VR-HMD 上での計測1056個と PC モニタ上での計測1055個あった。PC モニタだけ1個少ないのは計測装置の不具合による欠損のためであり、これは除外することとした。各表示画像に嗜好性の正解ラベルの付与は、画像の選択回数が最大選択回数の2/3を超える場合を「好き」1/3以下の場合を「好きでない」として分類を行った。今回は12枚画像があるため、各画像は11回選択肢となる。そのため、8回以上選択されると「好き」、3回以下は「好きでない」とした。なお、イラスト画像や人物画像のみで分析する際は、それぞれ画像が6枚あるため、4回以上選択されると「好き」、それ2回以下は「好きでない」とした。今回は、画像の選択回数が最大選択回数の1/3を超えるかつ、2/3以下の場合にはどちらにも分類されないデータとして除外した。

表2. 各画像を見たときのデータを入力データとして機械学習をし、LOSO-CV で評価した時の推定精度

	All	Illustration	Human	
Subject	A	54.0%	80.0%	80.0%
	B	63.6%	55.6%	55.0%
	C	61.6%	85.0%	75.0%
	D	64.9%	80.0%	65.0%
	E	47.7%	68.4%	77.8%
	F	54.5%	55.0%	75.0%
	G	65.2%	68.4%	60.0%
	H	62.5%	52.6%	70.0%
Avg	59.3%	68.1%	69.7%	

4.2 表示デバイスによる特徴量の比較

PC monitor と VR-HMD におけるデータの違いを比較するため、各デバイスで取得したデータから抽出した特徴量に対して有意差検定を行い、有意差のあった特徴量数を分析した。有意差検定には t 検定(有意水準5%以下)を用いた。その結果、PC モニタ上で計測したデータから得られる特徴量の方が、有意差のある数量が多かった。このことから以降は PC モニタ上で得られたデータの特徴量を用いて分析と機械学習の推定を行う。

4.3 各データに対する嗜好性推定

機械学習で推定では、推定精度の向上と嗜好性推定に有効である特徴量の発見のために貪欲法によって入力データの特徴量選択をし、SVM を用いて推定を行う。推定は各画像を見たときのデータに対して、そのデータが「好き」「好きでない」ものどちらを見ているものかを推定するものとする。そのため、入力データは、各画像を見たときの計測データとなる。なお、貪欲法で選択される特徴量数は最大2個である。評価手法は、LOSO-CV(Leave One Subject Out Cross Validation)を用いる。LOSO-CV とは全データに対して、ある被験者のデータをテストデータとして、それ以外の被験者のデータを学習データとすることを全被験者分行う手法である。また、推定を行う際は、正解データの比率が不均衡にならないようにランダムサンプリングを行い、それぞれの入力データ数の調整を行った。

表2に貪欲法で特徴量選択した場合の各被験者における推定精度を示す。表の All, Illustration, Human はそれぞれイラスト画像と人物画像を混合したペアを見たとき、イラスト画像のみのペアを見たとき、人物画像のみのペアを見たときの計測データを入力として機械学習で推定した場合の推定精度を表す。Avg は全被験者の平均推定精度である。平均推定精度を見てみると最良でも7割弱となっている。

表 3. 画像をペア単位で見たときのデータを入力データとして機械学習をし、LOSO-CV で評価した時の推定精度とデータ数

	All		Illustration		Human		
	Acc	N	Acc	N	Acc	N	
Subject	A	81.3%	16	100.0%	4	100.0%	5
	B	62.5%	16	100.0%	3	100.0%	4
	C	50.0%	20	75.0%	4	75.0%	4
	D	58.3%	12	75.0%	4	100.0%	4
	E	68.8%	16	100.0%	4	100.0%	3
	F	93.8%	16	100.0%	4	75.0%	4
	G	77.8%	9	50.0%	4	100.0%	1
	H	75.0%	16	100.0%	4	75.0%	4
Avg, Total	70.9%	121	87.5%	31	90.6%	29	

貪欲法によって選択された特徴量を見た場合、Illustration と Human での推定時に β 波に関する特徴量が選択されていた。このことから、嗜好性が β 波に何らかの影響を及ぼす可能性が考えられる。

4.4 ペアデータに対する相対的嗜好性推定

次に機械学習での嗜好性推定の対象を 1 データ単位でなく、ペア単位に実施した場合を考える。すなわち、今回の実験のように 2 組の画像ペアを表示し、どちらの画像が好みかを予測する問題と定義する。前処理として、今回入力に用いるペアデータは、実験で得られたデータセットの内、片方が「好き」もう片方が「好きでない」となるペアのみとした。この時の「好き」「好きでない」のラベルは前述のルールを踏襲した。入力データは、ペアの始めの画像を見たときの特徴量の値から、後に画像を見たときの特徴量の値を減じたものとなっている。機械学習アルゴリズムと評価手法は前節と同じように SVM と LOSO-CV を用いる。

表 3 にペアデータにおいて貪欲法で特徴量選択し推定した場合の各被験者における推定精度とデータ数を示す。表中の Acc は推定精度、N は各被験者のデータ数である。平均推定精度を見てみると、各画像データに対して嗜好性を推定する場合に比べて、推定精度が向上することが分かる。これは、ペア単位で相対的なデータを選ぶことによって、「好き」と「好きでない」間の特長量の値の違いが現れやすくなるためだと考えられる。

貪欲法によって選択された特徴量は、All, Illustration, Human の間で異なる傾向があった。All では β 波, Illustration では β 波と β/α , Human では α 波に関する特徴量が選択されていた。図 6 に Human において選択された α 波の特徴量の箱ひげ図を示す。凡例の first は画像ペアにおいて最初の

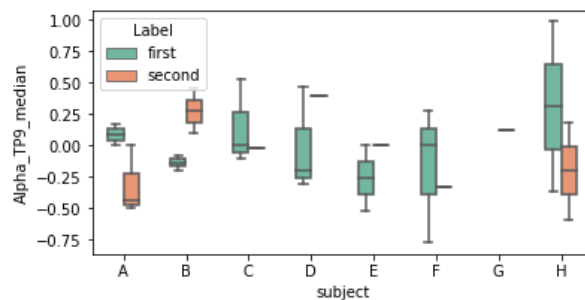


図 6. Human のデータを対象に被験者ごとに Alpha_TP9_median の値をプロットした箱ひげ図

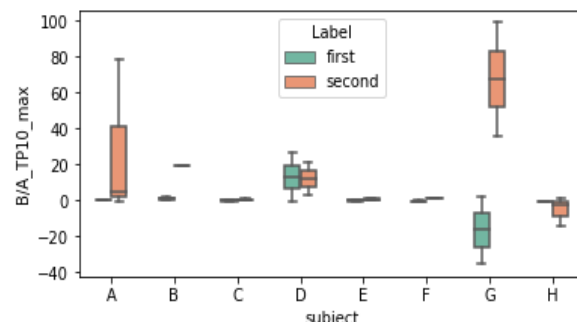


図 7. Illustration のデータを対象に被験者ごとに β/α _TP10_max の値をプロットした箱ひげ図

画像が「好き」、second は次の画像が「好き」であることを示す。また、ペアでデータを入力する際に、はじめの画像を見たときのデータの特徴量値一次の画像を見たときのデータの特徴量値をしているため、値が 0 より小さい場合は、次の画像を見たときの値が、0 より大きい場合は始めの画像を見たときの値が大きいことを示す。被験者 A, B, H を見てみると傾向が異なるものの、どれも first と second において差が出ていることが分かる。これは Kang ら[9]の研究で示されていた α 波と顔の好みへの関連性が現れているためだと考えられる。

図 7 は Illustration において平井ら[11]を参考にした β/α に関連する特徴量の値を被験者ごとに箱ひげ図にしたものである。被験者 A, G を見てみると、second の値が大きくなっていることが分かる。このことから、最初の画像が「好きでない」もの場合、 β/α の値が大きくなることが分かる。平井ら[11]では、音楽鑑賞の際に好みのジャンルになるほど β/α が低下、逆では増加するという結果となっていたが、それと同じような傾向が今回の実験でも見られた。このことから、各被験者でこの傾向の有無があることや被験者 H のように逆の傾向を示す場合があるものの、視覚的な嗜好性の推定に関してもこの特徴量が有効である可能性が示唆された。

5. まとめ

本研究では脳波から機械学習を用いた嗜好性推定および特徴量の分析を行った。機械学習の際、入力データは貪欲

法により特徴量選択を行った。機械学習の推定では入力データの形式を2種類用いた。入力データが各画像を見たときのデータである場合、平均推定精度は、最大でも7割弱であったのに対し、ペア単位を1つの入力データとして推定を行った場合、平均推定精度の向上が見られた。また、貪欲法で選択された特徴量を見てみると、 β 波や α 波の特徴量が選択されており、これらの特徴量や β/α などの特徴量が嗜好性の推定に対して有効である可能性が示された。

本研究では、表示画像にイラスト画像と人物写真を用いたが、これらの画像は2次元の画像であったためVR空間の利点を生かし切れていなかった。また、3Dモデルを用いた際に、臨場感を感じることで嗜好性を反映したデータが計測できる可能性があることから、2次元キャラクタ及び3Dモデルを用いたデータ分析及び特徴量分析を行いたい。

最終的には、嗜好推定後、嗜好性を反映した画像の生成および教示者画像の置き換えを行う。そして、嗜好性を刺激することにより、学習意欲が向上するかを含め、置き換えによる学習者への学習効率への影響を調査する。

謝辞

本研究の一部は科学研究費助成事業若手研究（19K20420）の助成及び、公益財団法人科学技術融合振興財団の補助金助成によるものである。ここに謝意を表す。

参考文献

- [1] 中野彰, : ” 反転授業の動向と課題”, 情報教育研究センター紀要, 2015
- [2] 富永 敦子, 向後 千春, : “eラーニングに関する実践的研究の進展と課題”, 教育心理学年報, 2014
- [3] Hamid, A., Pettibone, J., Mabrouk, O., Hetrick, V. et al.: ” Mesolimbic dopamine signals the value of work”, *Nature neuroscience*, 2016.
- [4] Takahashi, K., Mizuno, K., Sasaki, A. T. et al.: ”Imaging the passionate stage of romantic love by dopamine dynamics”, *Front Hum Neurosci*. 2015;9:191. Published 2015 Apr 9. doi:10.3389/fnhum.2015.00191.
- [5] Salimpoor, V., Benovoy, M., Larcher, K. et al.: “Anatomically distinct dopamine release during anticipation and experience of peak emotion to music”, *Nat Neurosci* 14, 257–262 (2011). <https://doi.org/10.1038/nn.2726>.
- [6] Varela, F., Lachaux, J., Rodriguez, E. et al.: “The brainweb: Phase synchronization and large-scale integration”, *Nat Rev Neurosci* 2, 229–239 (2001). <https://doi.org/10.1038/35067550>.
- [7] Ott, M., Freina, L.: “A literature review on immersive virtual reality in education: state of the art and perspectives”, In *The International Scientific Conference eLearning and Software for Education*, 2015.
- [8] Wang, K.: “Research on the Application of VR Technology in Logistics Equipment Application and Management Course Teaching”, In *proc. of the ICEIEM 2019*
- [9] Kang, J.H., Kim, S.J., Cho, Y.S., et al.: “Modulation of Alpha Oscillations in the Human EEG with Facial Preference.” *PLoS ONE* 10(9): e0138153.
- [10] Lindsen, P. J., Jones, R., Shinsuke, S., et al.: “Neural components underlying subjective preferential decision making”, *NeuroImage*, (2010)
- [11] 平井章康, 吉田幸二, 宮地功, : “簡易脳波計による学習時の思考と記憶の比較分析”, *マルチメディア, 分散協調とモバイルシンポジウム 2013 論文集*, pp. 1441– 1446 (2013)